


UNIVERSIDADE FEDERAL DO PARANÁ

CÍCERO JORGE FONSECA DOLÁCIO

BIOMASSA AÉREA E ESTOQUE DE CARBONO INDIVIDUAL EM DIFERENTES
MATERIAIS GENÉTICOS DE *Eucalyptus* NO ESTADO DO PARÁ

CURITIBA

2019



CÍCERO JORGE FONSECA DOLÁCIO

BIOMASSA AÉREA E ESTOQUE DE CARBONO INDIVIDUAL EM DIFERENTES
MATERIAIS GENÉTICOS DE *Eucalyptus* NO ESTADO DO PARÁ

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal.

Orientador: Prof. Dr. Nelson Yoshihiro Nakajima
Coorientadores: Prof. Dr. Ângelo Augusto Ebling
Prof. Dr. Dimas Agostinho Silva

CURITIBA

2019

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Dolácio, Cícero Jorge Fonseca

Biomassa aérea e estoque de carbono individual em diferentes
materiais genéticos de *Eucalyptus* no estado do Pará / Cícero
Jorge Fonseca Dolácio. – Curitiba, 2019.
155 f. : il.

Orientador: Prof. Dr. Nelson Yoshihiro Nakajima

Coorientadores: Prof. Dr. Ângelo Augusto Ebling

Prof. Dr. Dimas Agostinho Silva


Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de
Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal.
Defesa: Curitiba, 22/02/2019.

Área de concentração: Manejo Florestal.

1. Biomassa vegetal - Modelos matemáticos - Pará. 2. Biomassa
vegetal - Métodos estatísticos - Pará. 3. Eucalipto - Pará. 4. Carbono. 5.
Teses. I. Nakajima, Nelson Yoshihiro. II. Ebling, Ângelo Augusto. III. Silva,
Dimas Agostinho. IV. Universidade Federal do Paraná, Setor de Ciências
Agrárias. V. Título

CDD – 634.9

CDU – 634.0.548(811.5)




MINISTÉRIO DA EDUCAÇÃO
SETOR SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0


TERMO DE APROVAÇÃO

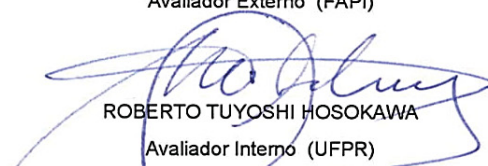
Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **CÍCERO JORGE FONSECA DOLÁCIO** intitulada: **Biomassa Aérea e Estoque de Carbono Individual em Diferentes Materiais Genéticos de *Eucalyptus* no Estado do Paraná.**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua Aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 22 de Fevereiro de 2019.


NELSON YOSHIHIRO NAKAJIMA
Presidente da Banca Examinadora (UFPR)


THAIS ESPINOLA DE OLIVEIRA LIMA
Avaliador Externo (FAPI)


ROBERTO TUYOSHI HOSOKAWA
Avaliador Interno (UFPR)



Dedico este trabalho à memória de minha Avó, Maria Carmelita da Fonseca, e ao meu Avô, José Ferreira de Oliveira. Juntos venceram as adversidades de seu tempo, com dedicação ao trabalho, esforço e honestidade; e sempre desejaram me ver formado, mas sequer imaginavam que eu poderia ser Mestre.

AGRADECIMENTOS

À minha Mãe, Maria Tanisladia da Fonseca, que mesmo distante se fez presente diariamente com seu Amor e Educação, possibilitando-me, com isso, concluir o mestrado. Sem ela, certamente, não conseguiria alcançar este objetivo.

Ao meu Amigo, Rudson Silva Oliveira, pela companhia nesses anos e pela parceria no incansável trabalho de coleta dos dados em campo e nas atividades de laboratório.

Ao Professor Orientador, Nelson Yoshihiro Nakajima, pela confiança e paciência tida comigo durante o desenvolvimento e conclusão desta dissertação.

A todos os meus familiares, que sempre acreditaram em mim e que, em função disso, me incentivaram a concluir o mestrado.

Aos meus Coorientadores, Ângelo Augusto Ebling e Dimas Agostinho da Silva, por partilharem parte dos seus conhecimento para o desenvolvimento e conclusão desta dissertação.

As amigas, Evelyn Poliana Santos Patrício e Chayanne Costa Lopes, pela companhia e pela imensurável ajuda nas atividades de laboratório.

À Universidade Federal do Paraná, pela oportunidade de realizar o mestrado e aos Professores e Mestres por contribuírem imensamente com a minha formação.

À Universidade Federal Rural da Amazônia, Campus de Parauapebas, e a alguns Docentes por disponibilizarem seus laboratórios para realização dos processamentos e das análises das amostras.

Ao Amigo e Mestre, Jonas Elias Castro da Rocha, pelo incentivo a novas descobertas desde a graduação e a seguir na vida acadêmica.

Ao grupo Concrem, em especial à Concrem Wood, pelo subsídio e fomento à realização da coleta dos dados em suas áreas experimentais.

A todos os amigos e colegas da Universidade Federal do Paraná, em especial aos do laboratório de Manejo de Florestas Nativas, pelo convívio e pelas discussões edificadoras que contribuíram diretamente para conclusão desta dissertação.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, pelo fomento para realização desta dissertação.

Por fim, a todos que contribuíram para conclusão de mais esta etapa da minha vida, seja de forma direta ou indireta.

RESUMO

No Estado do Pará, informações científicas sobre produção de biomassa seca e estoque de carbono em povoamentos de eucalipto são incipientes. Nesse sentido, justifica-se a realização de estudos nessa região para indicar materiais genéticos que garantam alta produção de biomassa combinada à elevada capacidade de estocar carbono e, também, para indicar qual método estima com maior precisão a biomassa seca e o estoque de carbono. Os principais objetivos deste estudo foram comparar a produção de biomassa e o estoque de carbono de diferentes componentes aéreos, entre materiais genéticos de *Eucalyptus*, por análise univariada e agrupá-los com análise multivariada; e investigar se equações alométricas desenvolvidas por rede neural artificial (RNA) estimam com maior precisão a biomassa seca e o estoque de carbono dos componentes aéreos, em comparação com as estimativas feitas por equações desenvolvidas por regressão não linear. Foram analisados dez materiais genéticos de *Eucalyptus* aos 4,6 anos de idade, sendo coletadas seis árvores amostras por material genético, totalizando 60 árvores para a estimativa da biomassa seca e do carbono orgânico dos diferentes componentes aéreos pelo método destrutivo. A análise de agrupamento hierárquico foi aplicada para agrupar os materiais genéticos com os dados multivariados, testando-se diferentes combinações de medidas de similaridade com métodos aglomerativos. Para o desenvolvimento das equações alométricas por componente, foi utilizada regressão não linear e rede neural artificial, sendo utilizados como variáveis preditoras o diâmetro com casca a 1,30 m de altura (dap_{cc}) e a altura total (h_t), além dos materiais genéticos na RNA. Observou-se que a distância de Canberra, combinada com as médias não ponderadas de grupos pareados, proporcionou a melhor combinação para o agrupamento dos materiais genéticos. O grupo 2 formado pelos materiais genéticos C-408, C-455 e C-479, apresentou estatisticamente maiores quantidades de biomassa e de carbono nos componentes lenho, total, tronco e copa. As equações desenvolvidas com rede neural artificial foram mais precisas apenas para a estimativa da biomassa seca e do carbono estocado nas folhas, nos galhos vivos e na copa. Já as equações desenvolvidas por regressão não linear forneceram estimativas mais precisas da biomassa seca e do carbono estocado nos componentes galhos secos, casca, lenho, total e tronco. Apenas com a utilização do dap_{cc} gerou-se equações mais precisas da biomassa seca e do carbono estocado nas folhas e na casca, contudo, a inclusão da h_t aumentou a precisão das estimativas nos componentes galhos secos, galhos vivos, lenho, total, copa e tronco.

Palavras-chave: Modelagem alométrica. Produção de biomassa. Rede neural artificial. Regressão não linear. Sequestro de carbono.

ABSTRACT

In the State of Pará, scientific information about production of dry biomass and carbon stock in eucalypt stands are incipient. In this sense, it is justified to carry out studies in this region to indicate genetic materials that provide high biomass production combined with the high capacity to stock carbon and to indicate which method estimates the dry biomass and the carbon stock more accurately. The main objectives of this study were to compare the biomass production and the carbon stock of different aboveground components among *Eucalyptus* genetic materials by univariate analysis and group them with multivariate analysis, and to investigate if allometric equations developed by artificial neural network (ANN) estimate accurately the dry biomass and the carbon stock of the aboveground components compared to the estimates made by equations developed by nonlinear regression. Ten genetic materials of *Eucalyptus* were analyzed at the 4.6 years of age and six sample trees were collected per genetic material totaling 60 trees for the estimation of dry biomass and organic carbon of the different aboveground components, by the destructive method. Hierarchical clustering analysis was applied to group the genetic materials with the multivariate data, testing different combinations of similarity measures with agglomerative methods. For the development of the allometric equations per components nonlinear regression and artificial neural networking were used, using as predictor variables the diameter with bark at 1.30 m from the ground (dbh_{wb}) and the total height (h_t), besides the genetic materials in ANN. It was observed that the Canberra distance combined with the unweighted pair group method with arithmetic mean provided the best combination for clustering of genetic materials. The group 2 formed by genetic material C-408, C-455 and C-479 presented statistically higher amounts of biomass and carbon in the stem wood, total, bole and crown components. The equations developed with artificial neural network were more accurate only for the estimation of the dry biomass and the carbon stocked in the leaves, living branches and the crown. In addition, the equations developed by nonlinear regression provided more accurate estimates of the dry biomass and carbon stocked in the dead branch, bark, stem wood, total and bole components. The use of only dbh_{wb} were generated more precise equations of dry biomass and carbon stocked in the leaves and bark, however, the inclusion of h_t increased the precision of the estimates in the dead branches, living branches, stem wood, total, crown and bole components.

Keywords: Allometric modeling. Biomass production. Artificial neural network. Nonlinear regression. Carbon sequestration.

LISTA DE FIGURAS

FIGURA 1 – CROQUI DOS TALHÕES E DOS MATERIAIS GENÉTICOS DA ÁREA EXPERIMENTAL	23
FIGURA 2 – DISTRIBUIÇÃO DIAMÉTRICA DOS DIFERENTES MATERIAIS GENÉTICOS	26
FIGURA 3 – ESTRUTURA DE UMA RNA COM CINCO NEURÔNIOS NA CAMADA INTERMEDIÁRIA	34
FIGURA 4 – DENDROGRAMAS OBTIDOS PELA ANÁLISE DE AGRUPAMENTO EM FUNÇÃO DA MÉDIA DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES	43
FIGURA 5 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR.	49
FIGURA 6 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	50
FIGURA 7 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	52
FIGURA 8 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR.	55
FIGURA 9 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	56
FIGURA 10 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO	

COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	58
FIGURA 11 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR.....	61
FIGURA 12 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	62
FIGURA 13 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	64
FIGURA 14 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	67
FIGURA 15 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	68
FIGURA 16 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS melhores EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	70
FIGURA 17 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO	

COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	73
FIGURA 18 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	74
FIGURA 19 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	76
FIGURA 20 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	79
FIGURA 21 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	80
FIGURA 22 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	82
FIGURA 23 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	85
FIGURA 24 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO	

COMPONENTE COPA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	86
FIGURA 25 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	88
FIGURA 26 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	91
FIGURA 27 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	92
FIGURA 28 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	94

LISTA DE TABELAS

TABELA 1 – VARIÂNCIA DO DIÂMETRO E NÚMERO DE INDIVÍDUOS AMOSTRADOS POR MATERIAL GENÉTICO	24
TABELA 2 – NÚMERO DE CLASSES DIAMÉTRICAS E INTERVALO DE CLASSE PARA CADA MATERIAL GENÉTICO	25
TABELA 3 – TEOR MÉDIO DE BIOMASSA SECA DAS AMOSTRAS DOS COMPONENTES POR MATERIAL GENÉTICO \pm DESVIO PADRÃO	28
TABELA 4 – TEOR MÉDIO DE CARBONO ORGÂNICO DAS AMOSTRAS DOS COMPONENTES POR MATERIAL GENÉTICO \pm DESVIO PADRÃO	29
TABELA 5 – MATERIAIS GENÉTICOS AVALIADOS NO EXPERIMENTO	29
TABELA 6 – MODELOS ALOMÉTRICOS AJUSTADOS POR REGRESSÃO NÃO LINEAR PARA ESTIMATIVA DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES AVALIADOS.....	31
TABELA 7 – TESTE DE HOMOGENEIDADE DAS VARIÂNCIAS DAS AMOSTRAS DE BIOMASSA E DO CARBONO ORGÂNICO CONSIDERANDO AS DIFERENÇAS ENTRE OS MATERIAIS GENÉTICOS.....	37
TABELA 8 – MÉDIAS DA BIOMASSA SECA (kg árvore ⁻¹) DOS COMPONENTES POR MATERIAL GENÉTICO	38
TABELA 9 – MÉDIAS DO CARBONO ORGÂNICO (kg árvore ⁻¹) DOS COMPONENTES POR MATERIAL GENÉTICO	40
TABELA 10 – COEFICIENTES DE CORRELAÇÃO COFENÉTICA DAS COMBINAÇÕES ENTRE AS MEDIDAS DE DISTÂNCIA E OS MÉTODOS AGLOMERATIVOS PARA AGRUPAMENTO DOS MATERIAIS GENÉTICOS.....	41
TABELA 11 – CLASSIFICAÇÃO DOS MATERIAIS GENÉTICOS EM QUATRO GRUPOS.....	44
TABELA 12 – TESTE DE HOMOGENEIDADE DAS VARIÂNCIAS DAS AMOSTRAS DE BIOMASSA E DO CARBONO ORGÂNICO CONSIDERANDO AS DIFERENÇAS ENTRE OS GRUPOS DE MATERIAIS GENÉTICOS	44

TABELA 13 – MÉDIAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO (kg árvore ⁻¹) NOS COMPONENTES POR GRUPO DE MATERIAIS GENÉTICOS	45
TABELA 14 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS	47
TABELA 15 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	48
TABELA 16 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	49
TABELA 17 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA .	51
TABELA 18 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS	53
TABELA 19 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR.	54
TABELA 20 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	55
TABELA 21 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS MELHORES	

EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	56
TABELA 22 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS.....	59
TABELA 23 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR.	60
TABELA 24 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	61
TABELA 25 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....	63
TABELA 26 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA .	64
TABELA 27 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	65
TABELA 28 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	67
TABELA 29 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA .	69

TABELA 30 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO .71	71
TABELA 31 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR71	71
TABELA 32 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA73	73
TABELA 33 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA .75	75
TABELA 34 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES76	76
TABELA 35 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR77	77
TABELA 36 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA79	79
TABELA 37 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA.....81	81

TABELA 38 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA ...	83
TABELA 39 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	84
TABELA 40 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA.....	85
TABELA 41 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA .	87
TABELA 42 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO	89
TABELA 43 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR	89
TABELA 44 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA	91
TABELA 45 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA .	93

SUMÁRIO

1	INTRODUÇÃO	19
1.1	OBJETIVOS	21
1.1.1	Objetivo geral	21
1.1.2	Objetivos específicos	21
2	MATERIAL E MÉTODOS	23
2.1	ÁREA EXPERIMENTAL	23
2.2	COLETA DOS DADOS	24
2.2.1	Biomassa seca dos componentes	27
2.2.2	Carbono orgânico estocado na biomassa seca dos componentes	28
2.3	DELINEAMENTO EXPERIMENTAL E ANÁLISE ESTATÍSTICA	29
2.3.1	Análise estatística multivariada	30
2.4	MODELAGEM ALOMÉTRICA	31
2.4.1	Regressão não linear	31
2.4.2	Rede neural artificial	32
2.4.3	Qualidade das estimativas	35
3	RESULTADOS E DISCUSSÃO	37
3.1	ANÁLISE ESTATÍSTICA UNIVARIADA POR MATERIAL GENÉTICO	37
3.1.1	Biomassa seca	37
3.1.2	Estoque de carbono orgânico	39
3.2	ANÁLISE ESTATÍSTICA MULTIVARIADA	41
3.2.1	Análise estatística univariada por grupo de materiais genéticos	44
3.3	MODELAGEM ALOMÉTRICA	46
3.3.1	Componente folhas	47
3.3.2	Componente galhos vivos	53
3.3.3	Componente galhos secos	59
3.3.4	Componente casca	64
3.3.5	Componente lenho	70
3.3.6	Total dos componentes	76
3.3.7	Componente copa	83
3.3.8	Componente tronco	88
4	CONCLUSÕES	96
	REFERÊNCIAS	97

APÊNDICE 1 – ANÁLISES DE VARIÂNCIA POR MATERIAIS GENÉTICOS	110
APÊNDICE 2 – AGRUPAMENTOS DE TODAS AS MEDIDAS DE SIMILARIDADE COMBINADAS AOS MÉTODOS AGLOMERATIVOS	114
APÊNDICE 3 – ANÁLISES DE VARIÂNCIA POR GRUPOS DE MATERIAIS GENÉTICOS	116
APÊNDICE 4 – QUALIDADE DAS ESTIMATIVAS PARA O CONJUNTO DE AJUSTE/TREINAMENTO DAS DEMAIS EQUAÇÕES	120
APÊNDICE 5 – GRÁFICOS DE RESÍDUOS PARA O CONJUNTO DE AJUSTE/TREINAMENTO DAS DEMAIS EQUAÇÕES	127
APÊNDICE 6 – QUALIDADE DAS ESTIMATIVAS PARA O CONJUNTO DE TESTE DAS DEMAIS EQUAÇÕES	133
APÊNDICE 7 – GRÁFICOS DE RESÍDUOS PARA O CONJUNTO DE TESTE DAS DEMAIS EQUAÇÕES	141
APÊNDICE 8 – EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR REDE NEURAL ARTIFICIAL	149

1 INTRODUÇÃO

No mundo, a avaliação da biomassa florestal tornou-se uma importante questão por estar relacionada, principalmente, com a produção de energia renovável como alternativa para substituição dos combustíveis fósseis e para mitigação das mudanças climáticas por sequestro do carbono atmosférico.

Rathore et al. (2018) salientam que as árvores estão entre os mais importantes sumidouros de carbono dos ecossistemas terrestres, pois sequestram o dióxido de carbono atmosférico e o armazenam em forma de biomassa. Ainda, a prática de manejo florestal sustentável, a redução do desmatamento e os povoamentos florestais estão entre as opções de mitigação das mudanças climáticas mais econômicas (CHU, 2009; LÓPEZ-DÍAZ et al., 2017).

No Brasil, há povoamentos florestais com espécies do gênero de *Eucalyptus* em quase todos os Estados, sendo registrado uma superfície plantada em nível nacional de 5,67 milhões de hectares em 2016 (INDÚSTRIA BRASILEIRA DE ÁRVORES, 2017). Esses povoamentos são reconhecidos mundialmente pela elevada produtividade, inclusive de biomassa e de sequestro de carbono, mas para isto acontecer, foram necessários estudos que indicassem sítios com combinação ótima dos atributos biofísicos, para favorecimento da produção.

Garlet et al. (2016) atentam ao fato de que povoamentos florestais com espécies do gênero *Eucalyptus* têm se estendido a regiões diferentes das tradicionais. O Pará, Estado do presente estudo, registrou uma área plantada de 133.996 hectares em 2016, 2,73% maior que no ano anterior, sendo, por isso, o estado com a maior área plantada da região norte e o terceiro da região geoeconômica amazônica.

Na mesorregião sudeste do estado do Pará, informações técnicas e científicas sobre produção de biomassa e sobre estoque de carbono, inclusive em povoamentos florestais constituídos por espécies do gênero *Eucalyptus*, são escassas. Por isso, é necessário realizar estudos nessa região para fomentar investimentos das empresas do setor florestal, com informações concretas sobre quais materiais genéticos do gênero *Eucalyptus* podem ser implantados, considerando a melhor interação com os atributos biofísicos dos sítios, para garantir alta produção de biomassa e de estoque de carbono.

Para isso, também são necessários estudos que estimem com precisão a biomassa florestal ou o estoque de carbono, para auxiliar na formulação de políticas

públicas e de pesquisas relacionadas ao papel dos povoamentos florestais na mitigação das mudanças climáticas (ROJAS-GARCÍA et al., 2015; RADTKE et al., 2016), tornando a escolha de um método que estime precisamente essas variáveis como, possivelmente, o passo mais crucial para minimizar os custos e os erros nas estimativas (MOLTO et al., 2013).

Essas estimativas podem ser realizadas por métodos destrutivos (SOHRABI et al., 2016) e não destrutivos, representados por técnicas de sensoriamento remoto (CHABI et al., 2016), por técnicas de regressão (KUYAH et al., 2016) e por técnicas de aprendizado de máquina (DEB et al., 2017). Os métodos destrutivos são os mais precisos, porém são mais onerosos economicamente e demorados em comparação com os métodos não destrutivos (XIE et al., 2008) que requerem inicialmente uma amostragem destrutiva e representativa da população (ROXBURGH et al., 2015).

A regressão não linear está, atualmente, entre os métodos estatísticos mais utilizadas para desenvolvimento de equações que estimam a biomassa e o carbono estocado em árvores no mundo (AJIT et al., 2011; VERMA et al., 2014), cujo ajuste é realizado pelo estabelecimento de uma relação empírica ou biológica entre a biomassa ou o estoque de carbono nos componentes da árvore e as variáveis medidas diretamente na árvore, como o diâmetro medido a 1,3 m do nível do solo, a altura da árvore, o diâmetro da copa ou a densidade básica (CORNET et al., 2015; PHIRI et al., 2015; MENSAH et al., 2016), podendo essas variáveis serem utilizadas individualmente ou combinadas.

Contudo, Brahma et al. (2018) enfatizam que equações alométricas desenvolvidas por regressão não linear devem ser geradas preferencialmente por espécie e em um determinado sítio, pois equações generalizadas, que englobam diversidade de espécies e de sítios, podem gerar estimativas enviesadas para uma determinada espécie. A rede neural artificial pode ser um método confiável para solução deste problema, mas não foi, ainda, testada amplamente para estimativa da produção de biomassa florestal e do estoque de carbono orgânico, inclusive em povoamentos florestais constituídos por espécies do gênero *Eucalyptus*.

Vahedi (2016) relatou que as redes neurais artificiais fornecem estimativas mais precisas para a biomassa quando comparadas as estimativas das equações desenvolvidas por regressão não linear, isto pode ser atribuído, ao fato de que esse método melhor assimila, nos pesos e nos *bias* dos neurônios da rede, os padrões

existentes entre as variáveis de entrada e de saída (ÖZÇELİK et al., 2010), ajustando modelos complexos que não precisam ser especificados antecipadamente.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Considerando as hipóteses de que existiam materiais genéticos mais adaptados às condições biofísicas do sítio para produção de biomassa e para sequestro de carbono; e de que as estimativas com as equações desenvolvidas por redes neurais artificiais seriam mais precisas que as das equações desenvolvidas por regressão não linear, pois durante o treinamento das redes neurais artificiais foi possível utilizar os diferentes materiais genéticos como variável preditora. Os objetivos gerais desse estudo foram avaliar e selecionar materiais genéticos de *Eucalyptus* que garantam alta produção de biomassa aérea aliada a elevada capacidade de estocar carbono, com uso de técnicas estatísticas univariada e multivariada; e investigar se estimativas da biomassa aérea e do estoque de carbono em diferentes materiais genéticos de *Eucalyptus* são mais precisas com modelagem por rede neural artificial, em comparação com regressão não linear.

1.1.2 Objetivos específicos

- Estimar, por método destrutivo, a produção de biomassa em diferentes componentes acima do solo de diferentes materiais genéticos de *Eucalyptus*.
- Estimar, por método destrutivo, o estoque de carbono em diferentes componentes acima do solo de diferentes materiais genéticos de *Eucalyptus*.
- Selecionar materiais genéticos de *Eucalyptus* que garantam elevada produção de biomassa e de estoque de carbono, com o uso da análise multivariada de agrupamento.
- Ajustar modelos alométricos por regressão não linear para gerar equações que estimem a biomassa seca e o estoque de carbono nos diferentes componentes acima do solo.

- Treinar redes neurais artificiais para gerar equações que estimem a biomassa seca e o estoque de carbono nos diferentes componentes acima do solo.
- Indicar qual método gera a equação que estima com maior precisão a biomassa seca e o estoque de carbono dos diferentes componentes acima do solo.

2.2 COLETA DOS DADOS

Inicialmente, um inventário florestal piloto foi realizado na população de dez materiais genéticos, indicados pela empresa, aos 4,6 anos de idade, aproximadamente, no mês de setembro de 2017, onde, em cada material genético foram alocadas aleatoriamente três parcelas retangulares com área aproximada de 73 m². Nessas parcelas foi medido o diâmetro com casca a 1,30 m de altura (d_{apcc}), em centímetros, de todas as árvores, para se conhecer previamente a variância diamétrica e para definir a suficiência amostral necessária para cobrir toda variabilidade diamétrica (TABELA 1) com a fórmula proposta por Cochran (1965), considerando erro máximo de amostragem igual a 5% ao nível de 95% de probabilidade da distribuição t de *Student*. Quando a grandeza de amostragem se apresentou suficiente para garantir esse erro máximo para a população, o inventário foi considerado como definitivo, caso contrário foram alocadas parcelas até que houvesse a garantia da precisão requerida.

TABELA 1 – VARIÂNCIA DO DIÂMETRO E NÚMERO DE INDIVÍDUOS AMOSTRADOS POR MATERIAL GENÉTICO

Material genético	$t_{(0,95;g.l.)}$	CV(%)	$n_{estimado}$	$n_{amostrado}$
C-406	2,080	11,07	22	30
C-408	2,120	9,52	17	27
C-432	2,032	14,40	35	52
C-435	2,145	9,01	15	17
C-436	2,064	11,90	25	32
C-443	2,028	14,86	37	37
C-455	2,101	10,27	19	26
C-479	2,110	9,95	18	25
C-490	2,179	8,19	13	26
C-500	2,045	13,39	30	32

FONTE: O autor (2019).

LEGENDA: $t_{(0,95;g.l.)}$ é o valor tabelado da distribuição t de Student para $n_{amostrado}$ graus de liberdade e 95% de probabilidade, CV(%) é o coeficiente de variação do d_{apcc} , em percentagem, $n_{estimado}$ é o número mínimo de indivíduos a serem amostrados para garantir erro de amostragem de no máximo 5%, e $n_{amostrado}$ é o número de indivíduos amostrados no inventário.

A técnica da árvore estratificada foi utilizada como método de amostragem para seleção das árvores amostras por classe diamétrica. O número e o intervalo de classes diamétricas (TABELA 2), por material genético, foram definidos após cômputo dos indivíduos inventariados e aplicação da fórmula de Sturges (1926).

TABELA 2 – NÚMERO DE CLASSES DIAMÉTRICAS E INTERVALO DE CLASSE PARA CADA MATERIAL GENÉTICO

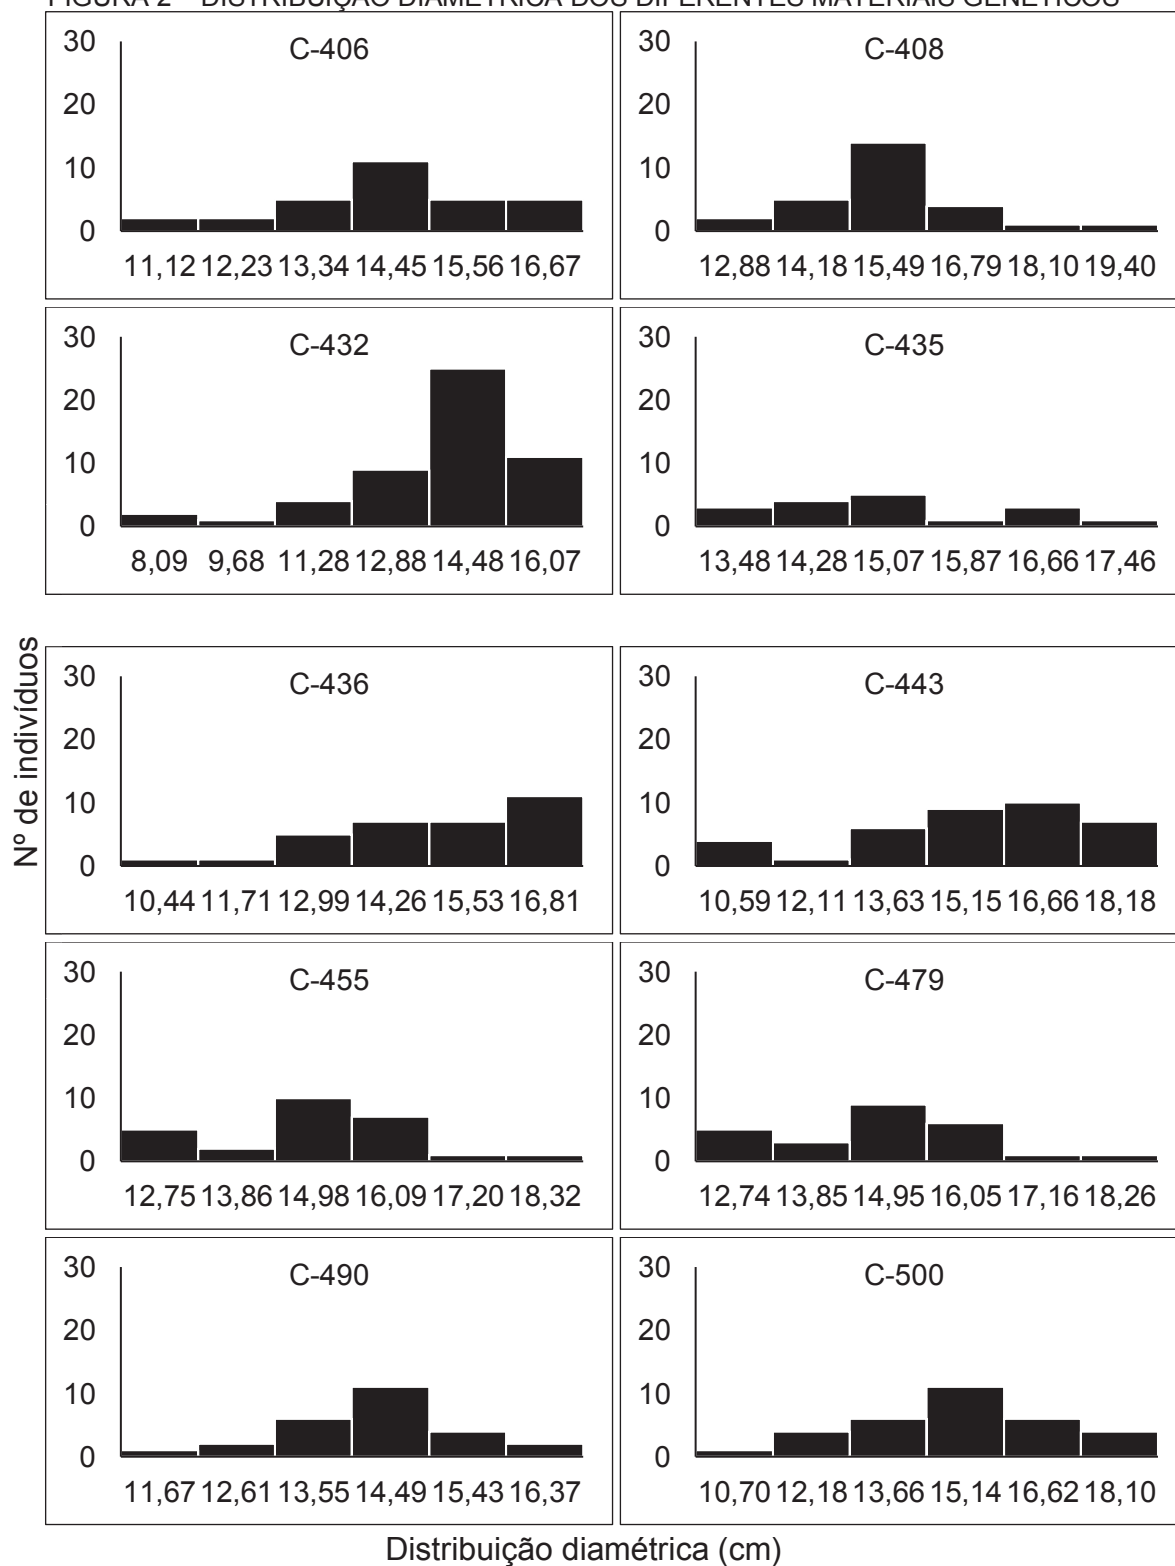
Informação Sturges	Material genético									
	C-406	C-408	C-432	C-435	C-436	C-443	C-455	C-479	C-490	C-500
N	6	6	7	6	7	7	6	6	6	7
N _{amostrado}	6	6	6	6	6	6	6	6	6	6
Ic	1,109	1,305	1,597	0,796	1,273	1,517	1,114	1,103	0,939	1,408

FONTE: O autor (2019).

LEGENDA: N é o número de classes diamétricas indicado pela fórmula de Sturges, N_{amostrado} é o número de classes diamétricas amostradas, e Ic é a amplitude de classe diamétrica considerando o N_{amostrado}.

O número definitivo de classes foi fixado em seis para todos os materiais genéticos, visando amostragem com número de classes equitativa e menos dispêndio em atividade de campo. A maioria dos materiais genéticos não apresentaram distribuição diamétrica dos indivíduos inventariados tendendo a normalidade, perfil esperado em povoamentos florestais plantados, cujas exceções foram os materiais genéticos C-408, C-490 e C-500 (FIGURA 2).

FIGURA 2 – DISTRIBUIÇÃO DIAMÉTRICA DOS DIFERENTES MATERIAIS GENÉTICOS



FONTE: O autor (2019).

No total, 60 árvores foram amostradas destrutivamente, sendo seis árvores por material genético, uma por classe diamétrica, mais próxima ao valor do centro de

cada classe, para estimativa da biomassa seca dos componentes (ms_c), e do carbono orgânico estocado na ms_c (co_c), ambos em kg.

2.2.1 Biomassa seca dos componentes

Com a possibilidade de a árvore derrubar galhos próprios e de outras árvores ao ser cortada, antes da derrubada foram coletados os galhos secos (gs) manualmente, da base até aproximadamente 2,10 m de altura, mitigando ao máximo possível perdas da amostra. Após a remoção parcial dos gs e a derrubada da árvore amostra, a altura total (h_t), em metros, foi medida e as ramificações remanescentes foram removidas do tronco, manualmente, e separadas em gs, galhos vivos (gv) e folhas (f), que foi separada, também, manualmente do gv sobre uma lona. O tronco foi subdividido em toras curtas, de aproximadamente 160 cm de comprimento e separada a casca (c) do lenho (le).

Todos os componentes da árvore foram pesados separadamente em campo para obtenção da biomassa úmida do componente (mu_c), em kg, com auxílio de uma balança digital de gancho suspensa. Ainda no campo, amostras dos componentes foram coletadas e pesadas imediatamente para obtenção da biomassa úmida da amostra (mu_a), em kg, assegurando igualdade da umidade relativa entre a mu_c e a mu_a .

Para as amostras de lenho e casca, foram retirados discos com 2,5 cm de espessura nas posições longitudinais: 2%, 10%, 30%, 50% e 75% da altura comercial, limitada a um diâmetro mínimo de 5 cm com casca (DOWNES et al., 1997) e na altura do dap_{cc} ; para os demais componentes foram coletadas amostras aleatórias com mu_a de 0,6 kg, em média.

No Laboratório de Produtos Florestais (LPF) da Universidade Federal Rural da Amazônia, Câmpus de Parauapebas, Pará, as amostras foram acondicionadas em sacos de papel kraft, com exceção dos discos, e todas foram deixadas para secar ao ar livre, posteriormente. Essas amostras passaram por um processo de pré-secagem a 55 ± 2 °C e de secagem a 103 ± 2 °C, em estufa com circulação forçada de ar, até a biomassa seca da amostra (ms_a), em kg, atingir peso constante. Para cada amostra foi calculado o teor de biomassa seca, em %, pela razão entre ms_a e mu_a (TABELA 3) e em seguida, a ms_c foi estimada pelo produto entre o valor dessa razão e a mu_c , em que a amostra foi retirada (EQUAÇÃO 1).

$$ms_c = \frac{ms_a}{mu_a} mu_c \quad (1)$$

TABELA 3 – TEOR MÉDIO DE BIOMASSA SECA DAS AMOSTRAS DOS COMPONENTES POR MATERIAL GENÉTICO ± DESVIO PADRÃO

Material genético	Componente				
	Galhos secos	Galhos vivos	Folhas	Casca	Lenho
C-406	88,96 ± 1,01%	35,93 ± 3,78%	27,74 ± 3,00%	47,28 ± 0,10%	50,15 ± 2,35%
C-408	87,15 ± 4,29%	31,76 ± 3,09%	32,17 ± 3,31%	44,33 ± 3,00%	47,13 ± 1,90%
C-432	88,88 ± 1,69%	36,73 ± 3,21%	32,81 ± 3,12%	44,58 ± 2,12%	47,70 ± 2,01%
C-435	87,80 ± 1,26%	39,40 ± 2,49%	39,38 ± 3,62%	46,33 ± 0,62%	46,11 ± 1,69%
C-436	88,41 ± 1,86%	39,15 ± 3,37%	33,44 ± 4,41%	47,50 ± 1,90%	44,61 ± 1,92%
C-443	88,78 ± 1,30%	40,04 ± 2,65%	35,36 ± 8,94%	45,49 ± 3,02%	43,85 ± 5,32%
C-455	88,94 ± 0,76%	40,42 ± 0,94%	35,27 ± 6,75%	44,73 ± 2,63%	48,16 ± 1,62%
C-479	88,45 ± 2,00%	41,63 ± 2,09%	36,87 ± 2,97%	46,81 ± 1,70%	49,16 ± 2,04%
C-490	87,76 ± 0,86%	38,90 ± 2,05%	30,54 ± 3,85%	46,76 ± 1,16%	44,72 ± 2,30%
C-500	86,53 ± 1,01%	32,77 ± 5,74%	32,66 ± 2,72%	47,79 ± 0,45%	47,75 ± 2,44%

FONTE: O autor (2019).

A biomassa seca do total dos componentes (ms_t), em kg, foi calculada pelo somatório das ms_c da árvore, além disso, a biomassa seca foi estimada para o tronco (ms_{tronco}), em kg, pelo somatório das ms_c lenho e casca, e para a copa (ms_{copa}), em kg, pela soma entre a ms_c galhos secos, galhos vivos e folhas.

2.2.2 Carbono orgânico estocado na biomassa seca dos componentes

Acreditando que o uso de um teor médio de 50% para estimar a quantidade de co_c poderia acarretar erro de subestimativa ou de superestimativa, a ms_a de todos os componentes foi moída totalmente, com exceção da ms_a do lenho que foi 50% moída e peneirada, em peneira com abertura de 0,250 mm (60 mesh). Uma subamostra de aproximadamente 0,100 g da ms_a retida na peneira com abertura de 0,074 mm (200 mesh) foi usada para a determinação do teor de carbono orgânico (tco), em %, (TABELA 4) por combustão a seco no analisador elementar LECO C-144 do Centro de Excelência em Pesquisas sobre Biomassa e Carbono (BIOFIX-UFPR).

TABELA 4 – TEOR MÉDIO DE CARBONO ORGÂNICO DAS AMOSTRAS DOS COMPONENTES POR MATERIAL GENÉTICO \pm DESVIO PADRÃO

Material genético	Componente				
	Galhos secos	Galhos vivos	Folhas	Casca	Lenho
C-406	46,51 \pm 0,76%	43,92 \pm 0,85%	48,40 \pm 0,73%	43,74 \pm 0,48%	44,14 \pm 0,42%
C-408	47,61 \pm 0,53%	44,02 \pm 0,23%	48,59 \pm 1,02%	41,69 \pm 1,63%	44,05 \pm 0,21%
C-432	46,68 \pm 0,66%	43,18 \pm 0,64%	49,64 \pm 1,08%	39,05 \pm 0,25%	44,43 \pm 0,63%
C-435	45,22 \pm 0,52%	42,97 \pm 0,35%	49,21 \pm 0,38%	42,76 \pm 0,91%	44,22 \pm 0,63%
C-436	44,80 \pm 0,68%	42,78 \pm 0,70%	48,56 \pm 0,87%	39,73 \pm 2,62%	44,90 \pm 0,28%
C-443	45,92 \pm 0,63%	41,41 \pm 0,39%	49,54 \pm 0,53%	39,28 \pm 0,50%	44,58 \pm 0,32%
C-455	46,51 \pm 0,32%	41,47 \pm 0,53%	49,51 \pm 0,62%	44,25 \pm 0,65%	44,74 \pm 0,40%
C-479	45,75 \pm 0,65%	40,97 \pm 0,29%	48,57 \pm 0,37%	42,89 \pm 0,59%	44,24 \pm 0,22%
C-490	47,04 \pm 0,49%	42,84 \pm 0,18%	48,75 \pm 0,65%	43,41 \pm 0,64%	43,93 \pm 0,28%
C-500	46,33 \pm 0,69%	43,44 \pm 0,24%	49,78 \pm 0,77%	36,59 \pm 0,75%	44,08 \pm 0,17%

FONTE: O autor (2019).

Após as análises, o co_c foi estimado pelo produto entre o tco do componente e a ms_c . Além das estimativas para co_c , foi realizada estimativa para o estoque de carbono orgânico total (co_{total}) pelo somatório dos co_c da árvore, para o estoque de carbono orgânico no tronco (co_{tronco}), calculado pelo somatório do co_c lenho e casca, e para o carbono orgânico estocado na copa (co_{copa}) foi somado o co_c galhos secos, galhos vivos e folhas.

2.3 DELINEAMENTO EXPERIMENTAL E ANÁLISE ESTATÍSTICA

Avaliação comparativa univariada das possíveis diferenças estatísticas entre os diferentes materiais genéticos (TABELA 5) nas quantidades de biomassa seca dos componentes folhas, galhos vivos, galhos secos, casca, lenho, total, copa e tronco; e de carbono orgânico estocado nesses componentes, foi realizada seguindo delineamento experimental em blocos casualizados.

TABELA 5 – MATERIAIS GENÉTICOS AVALIADOS NO EXPERIMENTO

Material genético	Descrição da espécie
C-406	<i>Eucalyptus urophylla</i>
C-408	<i>Eucalyptus urophylla</i>
C-432	Híbrido de polinização aberta
C-435	<i>Eucalyptus urophylla</i>
C-436	<i>Eucalyptus urophylla</i>
C-443	<i>Eucalyptus grandis</i> x <i>Eucalyptus tereticornis</i>
C-455	Híbrido de polinização aberta
C-479	<i>Eucalyptus urophylla</i> x <i>Eucalyptus grandis</i>
C-490	<i>Eucalyptus urophylla</i>
C-500	Híbrido de polinização aberta

FONTE: O autor (2019).

Inicialmente, as variâncias das amostras da biomassa seca e do carbono orgânico estocado em cada componente foram avaliadas quanto a homogeneidade pelo teste de Bartlett (1937) ao nível de 5% de significância e na hipótese de haver variâncias não homogêneas, as quantidades originais das variáveis seriam transformadas pelo método de Box e Cox (1964), para reduzir a variância entre as amostras (EQUAÇÃO 2), e para testar o efeito dos materiais genéticos e dos grupos de materiais genéticos (item 2.3.1) pelo teste de Fisher, na análise de variância (ANOVA).

$$y = \frac{y_i^\lambda - 1}{\lambda} \quad (2)$$

onde:

y = valor transformado da variável,

y_i = valor real da variável, e

λ = número real utilizado para transformação.

Quando o teste de Fisher revelou existir diferença estatisticamente significativa, ao nível de 95% de probabilidade de confiança, em pelo menos uma das médias, foi utilizado o teste de Scott e Knott (1974) ao nível de 5% de significância, para compará-las e agrupá-las sem qualquer sobreposição. Todas as análises foram realizadas no *software* R 3.5.1 (R CORE TEAM, 2018), com as funções “bartlett.test”, “boxcox” (VENABLES; RIPLAY, 2002), “aov” e “SK” (JELIHOVSCHI et al., 2014).

2.3.1 Análise estatística multivariada

Análise multivariada de agrupamento hierárquico foi outra abordagem aplicada para agrupar os materiais genéticos em função dos dados multivariados da ms_c , para identificar a similaridade entre os materiais genéticos, quando a intenção for produção de biomassa, e em função do co_c quando a intenção for utilizá-los como sumidouro de carbono.

Para tanto, foram testadas combinações entre as medidas de similaridade: distância euclidiana quadrática (Euclidiana), distância máxima (Máxima), distância de manhattan (Manhattan) e distância de canberra (Canberra), disponíveis na função “dist”; e os métodos aglomerativos: variância mínima de Ward (Ward), ligação simples (Simples), ligação completa (Completa), médias não ponderadas de grupos pareados

(UPGMA), médias ponderadas de grupos pareados (WPGMA), centroide ponderado do par de grupos (WPGMC) e centroide não ponderado do par de grupos (UPGMC), disponíveis na função “hclust”.

A melhor combinação foi definida pelo maior coeficiente de correlação cofenética (r_c), que mede a consistência do dendrograma, pela correlação entre as distâncias recuperadas do dendrograma e a matriz de distâncias originais (SOKAL; ROHLF, 1962), e para definição dos grupos foi utilizada análise visual, traçando-se a linha “fenon” no eixo da medida de similaridade. Todos os procedimentos foram realizados no *software* R, versão 3.5.1.

De acordo com Droogenbroeck et al. (2002), os dendrogramas resultantes de qualquer medida de similaridade em combinação com qualquer método de agrupamento, são considerados muito bem ajustados quando o r_c for maior que 0,9, já quando o r_c for maior ou igual a 0,8 e menor que 0,9 o ajuste deve ser considerado bom e abaixo de 0,8 indica mau ajuste.

2.4 MODELAGEM ALOMÉTRICA

2.4.1 Regressão não linear

Oito modelos alométricos não lineares, dependentes somente do dap_{cc} ou do dap_{cc} e da h_t , foram ajustados por regressão não linear para estimativa da biomassa seca dos componentes folhas, galhos vivos, galhos secos, casca e lenho; e do carbono orgânico estocado nesses componentes. Ainda, os modelos foram ajustados para estimar essas variáveis para o total dos componentes, para o tronco e para a copa (TABELA 6).

TABELA 6 – MODELOS ALOMÉTRICOS AJUSTADOS POR REGRESSÃO NÃO LINEAR PARA ESTIMATIVA DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES AVALIADOS

(continua)

Modelo	Fórmula	Fonte
Logístico	$y = \frac{\beta_0}{1 + \beta_1 \exp(-\beta_2 \text{dap}_{cc})} + \varepsilon_i$	Ricker (1979)
Monomolecular incompleto	$y = \beta_0 (1 - \exp(\beta_1 \text{dap}_{cc})) + \varepsilon_i$	Sena et al. (2015)

TABELA 6 – MODELOS ALOMÉTRICOS AJUSTADOS POR REGRESSÃO NÃO LINEAR PARA ESTIMATIVA DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES AVALIADOS

(conclusão)		
Modelo	Fórmula	Fonte
Michaelis-Menten	$y = \frac{\beta_0 \text{dap}_{cc}}{\beta_1 + \text{dap}_{cc}} + \varepsilon_i$	Brahma et al. (2017)
Exponencial	$y = \beta_0 \exp(\beta_1 \text{dap}_{cc}) + \varepsilon_i$	Gurdak et al. (2014)
Spurr	$y = \beta_0 (\text{dap}_{cc}^2 h_t)^{\beta_1} + \varepsilon_i$	Magalhães (2017)
Schumacher-Hall	$y = \beta_0 \text{dap}_{cc}^{\beta_1} h_t^{\beta_2} + \varepsilon_i$	Schumacher e Hall (1933)
Péllico Netto	$y = h_t (\beta_0 + \beta_1 \text{dap}_{cc} + \beta_2 (\text{dap}_{cc}^2)) + \varepsilon_i$	Péllico Netto (1979)
Hjelm-Johansson	$y = \beta_0 \left(2 + \frac{\text{dap}_{cc}}{h_t}\right) + \beta_1 (h_t^2) + \beta_2 (\text{dap}_{cc} h_t^2) + \varepsilon_i$	Hjelm e Johansson (2012)

FONTE: O autor (2019).

LEGENDA: y é a biomassa seca ou o carbono orgânico estocado nos componentes, em kg, β_0 , β_1 e β_2 são os coeficientes dos modelos a serem estimados, dap_{cc} é o diâmetro com casca medido a 1,30 m de altura, em cm, h_t é a altura total, em m, e ε_i é um erro aleatório, em kg.

Búrquez e Martínez-Yrizar (2011) recomendaram, veementemente, a utilização de modelos alométricos não lineares, pois em sua pesquisa apresentaram ajustes melhores, com maior precisão e com menos tendência, em comparação com modelos linearizados por transformação logarítmica, assim como Litton e Kauffman (2008). Os coeficientes dos modelos foram estimados pelo método dos mínimos quadrados não lineares, com a função “nls” presente no *software* R 3.5.1 (R CORE TEAM, 2018).

2.4.2 Rede neural artificial

Redes neurais artificiais (RNA) são algoritmos de aprendizado de máquina inspirados em redes neurais biológicas (CHEN et al., 2018), utilizadas para desenvolver equações que podem utilizar um grande número de variáveis de entrada sem que haja conhecimento prévio das relações destas com a variável de saída (SCHMITT et al., 2018).

A RNA é constituída por unidades de processamento interconectadas, denominadas neurônios (SANTOS et al., 2012), e estas carregam informações elementares da camada de entrada à camada de saída. Os valores das variáveis de entrada são geralmente padronizados e enviados aos neurônios da camada de

entrada para iniciar o aprendizado, estes são multiplicados por um peso sináptico, que representam as relações dos neurônios, e em seguida, este produto e um *bias* são somados e transferidos após passarem por uma função de ativação à próxima camada da RNA de forma iterativa até a camada de saída (ZHI et al., 2018).

Neste estudo, RNA do tipo *multilayer perceptron* (MLP), com arquitetura *feedforward* composta por uma camada de entrada, uma camada intermediária e uma camada de saída, foram treinadas para estimar a biomassa seca dos componentes folhas, galhos vivos, galhos secos, casca e lenho, e para estimar o carbono orgânico estocado nesses componentes. Ainda, foram treinadas RNA para o total dos componentes, para o tronco e para a copa.

A inclusão de camadas intermediárias poderia aumentar a flexibilidade das equações geradas, aumentando possivelmente a precisão, mas Hornik et al. (1989) mostraram que apenas uma camada intermediária foi o suficiente para modelar qualquer função contínua quando se utiliza uma boa quantidade de neurônios nesta camada. Redes *feedforward* possuem estrutura em camadas, e os neurônios de cada camada recebem sua entrada a partir do processamento dos neurônios da camada anterior e enviam sua saída a neurônios da camada seguinte, não havendo interconexões entre neurônios de uma mesma camada (NADERPOUR et al., 2018).

O algoritmo de treinamento *deeplearning* do pacote h2o (THE H2O.ai TEAM, 2017) presente no *software* R 3.5.1 foi utilizado para treinamento supervisionado e automatizado das RNA, sob orientação de parada antecipada quando a raiz do erro quadrático médio (REQM) do treinamento não melhorasse em pelo menos 0,01% por 10 ciclos consecutivos ou quando atingisse 1.000 ciclos no máximo, utilizando taxa de aprendizado igual a 0,005.

Na camada de entrada foram testados 11 e 12 neurônios, correspondentes ao dap_{cc} e materiais genéticos e ao dap_{cc} , h_t e materiais genéticos, respectivamente; os materiais genéticos foram inseridos como variável *Dummy*. Na camada intermediária, foi utilizada a função tangente hiperbólica para solução não linear e, o incremento progressivo de 3 a 6 neurônios foi a estratégia computacional utilizada para descobrir o número ideal de neurônios nesta camada; e na camada de saída foi utilizada a função linear no único neurônio, correspondente a biomassa seca ou ao carbono orgânico estocado nos componentes. A expressão matemática geral de uma RNA com cinco neurônios na camada intermediária está apresentada na EQUAÇÃO 3 e a estrutura geral dessa RNA pode ser visualizada na FIGURA 3.

$$y = b^2_1 + \sum_{j=1}^5 w^2_{1j} \frac{2}{1 + \exp^{-2(b^1_k + \sum_{j=1}^m x_j w^1_{kj})}} - 1 \quad (3)$$

Onde:

y = valor estimado da biomassa seca ou do carbono orgânico nos componentes,

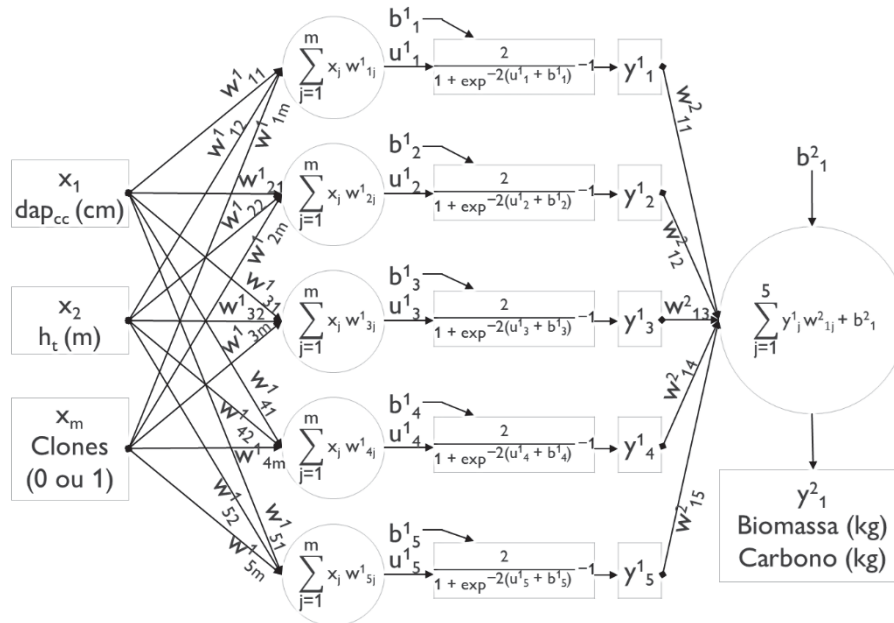
b^2_1 = *bias* do neurônio da camada de saída,

w^2_{1j} = vetor de pesos sinápticos das conexões dos cinco neurônios da camada intermediária com o único neurônios da camada de saída,

b^1_k = vetor de *bias* dos cinco neurônios da camada intermediária, e

w^1_{kj} vetor de pesos sinápticos das conexões dos neurônios da camada de entrada com os cinco neurônios da camada intermediária.

FIGURA 3 – ESTRUTURA DE UMA RNA COM CINCO NEURÔNIOS NA CAMADA INTERMEDIÁRIA



FONTE: O autor (2019).

Durante os treinamentos das RNA foi utilizado processo iterativo e o método de validação cruzada múltipla *k-fold* (JUNG, 2018), com quatro *folds* para determinar os melhores hiperparâmetros e para tentar evitar o problema de sobreajuste.

2.4.3 Qualidade das estimativas

Para verificar a qualidade das estimativas da regressão não linear e da rede neural artificial, os dados foram particionados sistematicamente em conjunto de ajuste/treinamento, com 66,7%, e em conjunto de teste, com 33,3%.

O teste é uma das partes mais importantes da modelagem, pois aumenta a credibilidade e a confiança sobre as equações (VANCLAY; SKOVSGAARD, 1997), e é realizado, geralmente, pela divisão de dados (FU et al., 2013). Mas, Kozak e Kozak (2003) salientaram que a qualidade do ajuste de equações alométricas por regressão, quando há divisão de dados para teste, não melhora significativamente em comparação com a qualidade do ajuste com um conjunto de dados sem divisão.

De acordo com Vanclay (1994), testar a equação com dados de pesquisas independentes que possuam características populacionais semelhantes é a melhor alternativa, mas isso não foi possível e mesmo com um pequeno conjunto de dados optou-se pela divisão, pois as redes neurais artificiais poderiam memorizar os dados utilizados no treinamento, acarretando numa péssima capacidade de generalização a novos dados.

Em ambos os conjuntos, a REQM e o coeficiente de correlação linear de Pearson (r_{yy}) foram utilizados como medidas de precisão, além disso, o teste de Shapiro e Wilk (1968) foi utilizado para testar a hipótese da normalidade na distribuição dos resíduos do conjunto de ajuste/treinamento e o teste Qui-quadrado (X^2) foi utilizado para verificar a existência de aderência ou de não aderência entre os valores previstos e observados do conjunto de teste, considerando um nível de 5% de significância em ambos testes.

Adicionalmente, a relação entre os valores previstos e observados do conjunto de ajuste/treinamento foi avaliada por uma equação linear simples, onde, o valor previsto foi considerado como a variável dependente e o valor observado como a variável independente, considerando, para tanto, melhores estimativas quando o coeficiente linear estiver mais próximo de zero e o coeficiente angular mais próximo de um, e, por fim, análise gráfica das estimativas, com resíduo padronizado, foi realizada.

As medidas de precisão foram calculadas com as funções “rmse” (HAMNER; FRASCO, 2018) e “cor”; os testes foram realizados com as funções “shapiro.test” e “pchisq”; os coeficientes da equação linear simples foram obtidos com a função “lm” e

os gráficos foram plotados com a função “residual.plot” (GELMAN; SU, 2018); todas implementadas no *software* R, versão 3.5.1.

3 RESULTADOS E DISCUSSÃO

3.1 ANÁLISE ESTATÍSTICA UNIVARIADA POR MATERIAL GENÉTICO

Com o valor de Qui-quadrado, referente ao teste de Bartlett, pode-se observar que todos os componentes avaliados apresentaram variâncias individuais dos materiais genéticos homogêneas, para a quantidade produzida de biomassa e de carbono orgânico estocado, com significância (p_{value}) maior que 0,05 (TABELA 7), não requerendo, portanto, transformação dos valores pelo método de Box e Cox.

TABELA 7 – TESTE DE HOMOGENEIDADE DAS VARIÂNCIAS DAS AMOSTRAS DE BIOMASSA E DO CARBONO ORGÂNICO CONSIDERANDO AS DIFERENÇAS ENTRE OS MATERIAIS GENÉTICOS

Componente	Biomassa		Carbono	
	X^2	p_{value}	X^2	p_{value}
Galhos secos	15,07	0,0891	10,63	0,3020
Galhos vivos	4,98	0,8363	5,41	0,7973
Folhas	5,12	0,8238	5,31	0,8065
Casca	2,95	0,9663	2,06	0,9904
Lenho	4,63	0,8649	4,83	0,8485
Total	3,96	0,9139	4,00	0,9114
Copa	4,30	0,8904	4,34	0,8878
Tronco	4,32	0,8894	4,37	0,8854

X^2 é o valor do Qui-quadrado calculado, referente ao teste de Bartlett, e p_{value} é a significância do valor Qui-quadrado calculado. FONTE: O autor (2019).

As análises de variância mostraram que há, entre as médias da produção de biomassa e da quantidade de carbono orgânico estocada nos diferentes materiais genéticos avaliados, pelo menos uma que se diferencia estatisticamente das demais, em todos os componentes avaliados, bem como no total, na copa e no tronco (APÊNDICE 1).

3.1.1 Biomassa seca

As comparações das médias pelo teste de Scott e Knott (TABELA 8) mostram que as produções de biomassa dos materiais genéticos C-455 e C-479, no componente galhos secos, foram estatisticamente similares entre si e maiores que as produções dos demais materiais genéticos. O C-455 está, também, entre os materiais genéticos que mais produziram biomassa no componente galhos vivos, mas sem diferença estatística das produções dos materiais genéticos C-408, C-435 e C-500,

além disso, foi o que apresentou, estatisticamente, maior produção de biomassa no componente folhas, com 49,6% a mais de biomassa que a quantidade do material genético C-435, segundo com maior produção, quantitativamente.

TABELA 8 – MÉDIAS DA BIOMASSA SECA (kg árvore⁻¹) DOS COMPONENTES POR MATERIAL GENÉTICO

Material genético	Componente							
	Galhos secos	Galhos vivos	Folhas	Casca	Lenho	Copa	Tronco	Total
C-408	2,47 b	5,33 a	3,07 b	7,19 b	99,77 a	10,87 b	106,95 a	117,83 a
C-455	3,72 a	6,12 a	5,25 a	7,45 b	91,57 a	15,10 a	99,01 a	114,11 a
C-479	4,59 a	3,85 b	3,50 b	8,14 b	91,04 a	11,94 b	99,18 a	111,12 a
C-435	1,40 c	5,70 a	3,51 b	10,11 a	79,27 b	10,61 b	89,39 b	100,00 b
C-500	1,42 c	4,79 a	3,26 b	7,38 b	75,43 b	9,47 c	82,81 c	92,28 c
C-406	0,98 c	3,93 b	3,11 b	5,46 c	77,12 b	8,01 c	82,57 c	90,58 c
C-490	3,04 b	2,82 b	2,94 b	5,77 c	71,14 b	8,81 c	76,90 c	85,71 c
C-443	3,22 b	3,27 b	2,15 c	6,12 c	68,66 b	8,64 c	74,78 c	83,42 c
C-436	1,77 c	3,13 b	2,38 c	6,25 c	61,05 c	7,29 c	67,29 d	74,58 d
C-432	3,00 b	2,88 b	2,46 c	4,27 d	47,85 d	8,34 c	52,12 e	60,46 e

FONTE: O autor (2019).

LEGENDA: Médias seguidas da mesma letra não diferem estatisticamente entre si, pelo teste de Scott e Knott, à um nível de 95% de probabilidade.

No componente casca, o material genético C-435 se destaca, estatisticamente, com a maior produção de biomassa, sendo esta, 1,97 kg superior (24,2%) a quantidade produzida pelo material genético C-479, segundo com maior produção, quantitativamente. Considerando a biomassa do componente lenho, os materiais genéticos C-408, C-455 e C-479 foram os únicos que apresentaram produção superior a 90,00 kg por árvore, em média, apresentando, portanto, produções estatisticamente superiores aos dos demais materiais genéticos e similares entre si.

Assim como para o componente lenho, os materiais genéticos C-408, C-455 e C-479 foram os que mais produziram biomassa no total e no tronco, em contrapartida, o C-432 foi o que menos produziu biomassa nesses componentes. Ainda, o material genético C-455 obteve a maior produção de biomassa no componente copa, com valor médio de 15,10 kg, por árvore; superioridade similar a apresentada no componente folhas, que é um componente que influencia diretamente na quantidade de biomassa produzida pela copa, assim como os galhos secos e galhos vivos.

As árvores amostras dos diferentes materiais genéticos apresentaram, em média, maior proporção de biomassa seca no componente lenho (82,02%) e menor proporção no componente galhos secos (2,75%), as proporções das produções nos

demais componentes foram de: 7,33% (casca), 4,50% (galhos vivos) e 3,40% (folhas). Viera et al. (2013) estimaram a quantidade de biomassa acima do solo em um povoamento de *Eucalyptus urophylla* x *E. globulus* com 10 anos de idade, em Eldorado do Sul-RS, e a madeira apresentou proporção de 84,20% do total, semelhante a estimada nesse trabalho, apesar da diferença entre as idades.

A produção total de biomassa do material genético C-432 foi a menor entre todos os materiais genéticos avaliados nesse estudo e é similar a biomassa estimada no exemplo de Montagu et al. (2005) para árvores de *Eucalyptus pilularis* em Hannam Vale, Austrália com 3,0 anos de idade. Esses autores indicam que a biomassa aérea total chegou a 62,0 kg árvore⁻¹, e que está particionada em 53% (32,86 kg árvore⁻¹), 28% (17,36 kg árvore⁻¹) e 19% (11,78 kg árvore⁻¹) para os componentes tronco, galhos e folhas.

António et al. (2007) estimaram a biomassa total aérea seca de árvores de *Eucalyptus globulus* plantados em vários sítios de Portugal e obtiveram valores que variaram de 0,60 kg árvore⁻¹ a 1.086,30 kg árvore⁻¹, para as idades de 0,6 anos e 19 anos, respectivamente, e o valor médio obtido foi de 129,40 kg árvore⁻¹ aos 7,8 anos. Ainda, o máximo valor estimado no trabalho de González-García et al. (2013) para biomassa aérea total de *Eucalyptus nitens*, implantados com alta densidade para colheita em curta rotação, foi 45,87 kg árvore⁻¹.

A produtividade total média dos melhores materiais genéticos encontrada nessa pesquisa é consideravelmente superior a encontrada na literatura para idades próximas de 4,6 anos e relativamente próxima das produtividades estimadas para idades superiores (LELES et al., 2001; PAUL et al., 2013), indicando que os materiais genéticos estudados estão bem adaptados as condições biofísicas do sítio.

3.1.2 Estoque de carbono orgânico

O teste de Scott e Knott comprova que houve diferença significativa, entre os diferentes materiais genéticos nas quantidades de carbono orgânico estocadas na biomassa de cada componente (TABELA 9). O material genético C-455 estocou maiores quantidades de carbono nos componentes folhas (2,59 kg) e copa (6,87 kg), estatisticamente. Ainda, este material genético, assim como o C-408 e o C-479 foram os responsáveis pelos maiores estoques nos componentes lenho, total e tronco.

TABELA 9 – MÉDIAS DO CARBONO ORGÂNICO (kg árvore⁻¹) DOS COMPONENTES POR MATERIAL GENÉTICO

Material genético	Componente							
	Galhos secos	Galhos vivos	Folhas	Casca	Lenho	Copa	Tronco	Total
C-408	1,18 b	2,35 a	1,49 b	2,98 c	43,97 a	5,01 b	46,95 a	51,96 a
C-455	1,73 a	2,54 a	2,59 a	3,29 b	40,91 a	6,87 a	44,21 a	51,07 a
C-479	2,11 a	1,58 b	1,70 b	3,49 b	40,29 a	5,38 b	43,78 a	49,16 a
C-435	0,63 c	2,45 a	1,73 b	4,33 a	34,98 b	4,81 b	39,31 b	44,12 b
C-500	0,66 c	2,08 a	1,63 b	2,69 c	33,23 b	4,37 c	35,93 c	40,30 c
C-406	0,45 c	1,73 b	1,51 b	2,39 d	34,04 b	3,69 c	36,42 c	40,11 c
C-490	1,43 b	1,21 b	1,44 b	2,50 d	31,27 b	4,08 c	33,77 c	37,85 c
C-443	1,48 b	1,35 b	1,07 c	2,41 d	30,61 b	3,91 c	33,03 c	36,93 c
C-436	0,80 c	1,34 b	1,16 c	2,50 d	27,42 c	3,30 c	29,92 c	33,22 d
C-432	1,40 b	1,24 b	1,24 c	1,67 e	21,29 d	3,87 c	22,95 d	26,83 e

FONTE: O autor (2019).

LEGENDA: Médias seguidas da mesma letra não diferem estatisticamente entre si, pelo teste de Scott e Knott, à um nível de 95% de probabilidade.

No componente galhos secos, os materiais genéticos C-455 e C-479 estocaram quantidades de carbono orgânico similares e maiores que as dos demais, já no componente galhos vivos, os materiais genéticos C-408, C-435, C-455 e C-500 foram os únicos que estocaram mais de 2,00 kg de carbono orgânico por árvore, em média, e não apresentaram diferenças entre si.

Os componentes casca e tronco foram os únicos que apresentaram diferenças nos grupos formados pelo teste de Scott e Knott, quando comparados os grupos da produção de biomassa e os grupos do estoque de carbono orgânico. As diferenças na quantidade de grupos, ao avaliar o estoque de carbono orgânico, indica de maneira geral, que nos componentes avaliados há maior ou menor tco, quando a quantidade de grupos formados diminui ou aumenta, respectivamente, em relação aos grupos da produção de biomassa.

No componente casca houve incremento de um grupo, em que os materiais genéticos C-408 e C-500, que compuseram o segundo grupo de maior produção de biomassa, passaram a compor o terceiro grupo na quantidade de carbono orgânico estocado e no componente tronco houve redução de um grupo, pois o material genético C-436 que estava no quarto grupo de produção de biomassa passou a compor o terceiro grupo na quantidade de estoque de carbono orgânico; tais diferenças provêm, certamente, da interação genética com o sítio.

Diferentemente do obtido nesse estudo, Bandara e Aththanayake (2018) avaliaram o teor de carbono no fuste de árvores de *Eucalyptus grandis* implantadas em quatro plantios no Sri Lanka, usando o método de perda de peso por ignição (ULLAH; AL-AMIN, 2012), e estimaram um teor médio de 64% no tronco. Contudo,

outros trabalhos da literatura indicaram que esse teor dificilmente ultrapassa 50% em espécies do gênero *Eucalyptus* (RIBEIRO et al., 2015).

O lenho foi o componente da árvore que mais contribuiu para a quantidade total de carbono orgânico estocado, seguido pela casca, galhos vivos, folhas e galhos secos. Em termos médios, com exceção das quantidades de carbono estocadas nos componentes galhos vivos e casca, as quantidades dos demais componentes foram superiores as encontrados por Silva et al. (2015), que estimaram 30,81 kg árvore⁻¹, 8,02 kg árvore⁻¹, 2,18 kg árvore⁻¹, 1,13 kg árvore⁻¹ e 0,63 kg árvore⁻¹ de carbono orgânico estocado nos componentes, lenho, casca, galhos vivos, folhas e galhos secos de árvores de *Eucalyptus* spp. com 4,7 anos, respectivamente.

3.2 ANÁLISE ESTATÍSTICA MULTIVARIADA

As combinações entre as medidas de similaridade e os métodos aglomerativos na análise multivariada de agrupamento para a média da produção de biomassa e do carbono orgânico por componente, geraram dendrogramas que, medidos pelo coeficiente de correlação cofenética, podem ser considerados muito bem ajustados, bem ajustados e mal ajustados (TABELA 10). Nota-se, ainda, que houve diferenças no ranqueamento desses coeficientes ao compará-los entre as variáveis.

TABELA 10 – COEFICIENTES DE CORRELAÇÃO COFENÉTICA DAS COMBINAÇÕES ENTRE AS MEDIDAS DE DISTÂNCIA E OS MÉTODOS AGLOMERATIVOS PARA AGRUPAMENTO DOS MATERIAIS GENÉTICOS

(continua)

Medida de Similaridade	Variável	Método aglomerativo						
		Ward	Simples	Completa	UPGMA	WPGMA	WPGMC	UPGMC
Euclidiana	Biomassa	0,593 (27)	0,645 (22)	0,614 (26)	0,702 (13)	0,641 (23)	0,730 (8)	0,733 (7)
Máxima		0,672 (17)	0,673 (16)	0,696 (14)	0,708 (9)	0,708 (9)	0,667 (18)	0,708 (9)
Manhattan		0,650 (21)	0,615 (25)	0,656 (20)	0,685 (15)	0,667 (18)	0,641 (23)	0,703 (12)
Canberra		0,902 (5)	0,928 (4)	0,934 (3)	0,941 (1)	0,940 (2)	0,467 (28)	0,840 (6)

TABELA 10 – COEFICIENTES DE CORRELAÇÃO COFENÉTICA DAS COMBINAÇÕES ENTRE AS MEDIDAS DE DISTÂNCIA E OS MÉTODOS AGLOMERATIVOS PARA AGRUPAMENTO DOS MATERIAIS GENÉTICOS

(conclusão)

Medida de Similaridade	Variável	Método aglomerativo						
		Ward	Simples	Completa	UPGMA	WPGMA	WPGMC	UPGMC
Euclidiana	Carbono	0,600 (25)	0,754 (8)	0,639 (21)	0,717 (14)	0,652 (19)	0,730 (12)	0,773 (7)
Máxima		0,570 (28)	0,709 (17)	0,590 (26)	0,746 (9)	0,714 (15)	0,721 (13)	0,738 (11)
Manhattan		0,632 (22)	0,620 (23)	0,660 (18)	0,712 (16)	0,651 (20)	0,611 (24)	0,739 (10)
Canberra		0,814 (6)	0,902 (3)	0,870 (4)	0,915 (1)	0,913 (2)	0,590 (26)	0,836 (5)

FONTE: O autor (2019).


NOTA: O ranqueamento dos coeficientes de correlação cofenética em ordem decrescente estão entre parênteses, por variável.

A distância de Canberra, quando combinada com a maioria dos métodos aglomerativos, apresentou os maiores r_c , em ambas variáveis, e a combinação entre essa distância e o método aglomerativo UPGMA (SOKAL; MICHENER, 1958), gerou os maiores r_c (0,941, para a biomassa, e 0,915, para o carbono), por melhor correlacionar à matriz de distâncias recuperadas do dendrograma com a matriz de distâncias original.

Por outro lado, a combinação entre a distância de Canberra com o método aglomerativo WPGMC gerou o menor r_c com os dados multivariados da produção de biomassa por componente e o método de variância mínima de Ward combinado com a máxima distância gerou o menor r_c no agrupamento com valores médios de estoque de carbono.

Ainda que não exista um critério objetivo para determinar um ponto de corte no eixo da medida de similaridade, e por consequência, o número ideal de grupos, pode ser visualizado na FIGURA 4 que a divisão dos dez materiais genéticos pôde ser feita em quatro grupos, ao traçar a linha *Fenon* próxima de 76% da maior distância de similaridade, no agrupamento dos materiais genéticos em função dos dados multivariados de biomassa por componente, e próxima de 78% da maior distância com os dados multivariados de carbono orgânico por componente. Os agrupamentos dessas variáveis, oriundos das demais combinações estão apresentados no APÊNDICE 2.

FIGURA 4 – DENDROGRAMAS OBTIDOS PELA ANÁLISE DE AGRUPAMENTO EM FUNÇÃO DA MÉDIA DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES



FONTE: O autor (2019).

Com a representação da similaridade, gerada pela combinação entre a medida de distância de Canberra e o método aglomerativo UPGMA, em um dendrograma, nota-se que os materiais genéticos C-443 e C-490 foram os que mais se assemelharam, quando avaliado os valores médios da produção de biomassa e do estoque de carbono orgânico por componente.

Na TABELA 11 verifica-se que o grupo 3 ficou constituído pela maioria dos materiais genéticos, e, em contrapartida, o grupo 1 ficou formado com a menor quantidade de materiais genéticos. Os grupos 2 e 4 ficaram compostos por três e dois materiais genéticos, respectivamente. Em função dessa similaridade, a formação dos grupos representa valiosa informação na escolha de materiais genéticos para produção de biomassa e para estoque de carbono.

TABELA 11 – CLASSIFICAÇÃO DOS MATERIAIS GENÉTICOS EM QUATRO GRUPOS

Grupo	Materiais genéticos
1	C-406
2	C-408 – C-455 – C-479
3	C-432 – C-436 – C-443 – C-490
4	C-435 – C-500

FONTE: O autor (2019).

Os materiais genéticos C-408, C-455 e C-479 ficaram agrupados em um mesmo grupo (grupo 2); isto pode ser explicado pelo fato de que a média da biomassa seca e do carbono orgânico desses materiais genéticos apresentam maiores quantidades em todos os componentes avaliados.

Apesar de existir formação de subgrupos dentro dos grupos que apresentaram pelo menos três materiais genéticos, estes não se formam com expressiva diferença, comprovando a consistência dos grupos formados e corroborando com o alto r_c , além disso, não se observou em nenhum dos grupos separação homogênea quanto à espécie dos materiais genéticos avaliados.

3.2.1 Análise estatística univariada por grupo de materiais genéticos

Com o valor do teste de Bartlett, pode-se observar que todos os componentes avaliados apresentaram variâncias individuais dos grupos de materiais genéticos, formados pela análise de agrupamento, homogêneas, para a quantidade produzida de biomassa e de carbono orgânico estocado, com significância maior que 0,05 (TABELA 12), não necessitando transformação dos valores.

TABELA 12 – TESTE DE HOMOGENEIDADE DAS VARIÂNCIAS DAS AMOSTRAS DE BIOMASSA E DO CARBONO ORGÂNICO CONSIDERANDO AS DIFERENÇAS ENTRE OS GRUPOS DE MATERIAIS GENÉTICOS

Componente	Biomassa		Carbono	
	X ²	p _{value}	X ²	p _{value}
Galhos secos	5,55	0,1356	5,63	0,1309
Galhos vivos	4,64	0,1998	4,94	0,1765
Folhas	1,75	0,6265	1,40	0,7065
Casca	2,32	0,5080	2,90	0,4068
Lenho	0,25	0,9687	0,19	0,9789
Total	0,28	0,9632	0,22	0,9744
Copa	2,03	0,5666	1,71	0,6352
Tronco	0,22	0,9746	0,15	0,9849

FONTE: O autor (2019).

LEGENDA: X² é o valor do Qui-quadrado calculado, referente ao teste de Bartlett, e p_{value} é a significância do valor Qui-quadrado calculado.

As análises de variância mostraram que existe, entre as médias da produção de biomassa e da quantidade de carbono orgânico estocada nos grupos formados pelos diferentes materiais genéticos avaliados, pela análise de agrupamento, no mínimo uma que se diferencia estatisticamente das demais, em todos os componentes avaliados, bem como no total, na copa e no tronco (APÊNDICE 3).

O teste de Scott e Knott comprova que houve, entre as médias de produção de biomassa e do estoque de carbono orgânico, por grupo, formado pela análise de agrupamento, pelo menos uma que se diferenciou estatisticamente das demais em todos os componentes avaliados, bem como no total, na copa e no tronco (TABELA 13).

TABELA 13 – MÉDIAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO (kg árvore⁻¹) NOS COMPONENTES POR GRUPO DE MATERIAIS GENÉTICOS

Grupo	Variável	Componente							
		Galhos secos	Galhos vivos	Folhas	Casca	Lenho	Total	Copa	Tronco
1	Biomassa	0,98 b	3,93 b	3,11 a	5,46 b	77,12 b	90,58 b	8,01 b	82,57 b
2		3,60 a	5,10 a	3,94 a	7,59 a	94,12 a	114,35 a	12,64 a	101,72 a
3		2,76 a	3,03 b	2,48 b	5,60 b	62,17 c	76,04 c	8,27 b	67,77 c
4		1,41 b	5,25 a	3,39 a	8,75 a	77,35 b	96,14 b	10,04 b	86,1 b
1	Carbono	0,45 b	1,73 b	1,51 a	2,39 b	34,04 b	40,11 b	3,69 b	36,42 b
2		1,67 a	2,15 a	1,93 a	3,25 a	41,73 a	50,73 a	5,75 a	44,98 a
3		1,28 a	1,29 b	1,23 b	2,27 b	27,65 c	33,71 c	3,79 b	29,92 c
4		0,64 b	2,27 a	1,68 a	3,51 a	34,11 b	42,21 b	4,59 b	37,62 b

FONTE: O autor (2019).

NOTA: Médias seguidas da mesma letra não diferem estatisticamente entre si, pelo teste de Scott e Knott, à um nível de 95% de probabilidade.

O grupo 2, formado pelos materiais genéticos C-408, C-455 e C-479, apresentou, quantitativamente, maiores valores médios de biomassa produzida e de carbono orgânico estocado em todos os componentes avaliados e, estatisticamente, essas médias foram maiores nos componentes lenho, total, copa e tronco.

No componente galhos secos, a média do grupo 3 (C-432, C-436, C-443 e C-490) foi similar à do grupo 2, assim como as médias produzidas pelo grupo 4 (C-435 e C-500) nos componentes galhos vivos, folhas e casca. O grupo 3 apresentou a menor produção de biomassa e o menor estoque de carbono, sozinho, nos componentes folhas, lenho, total e tronco, além de também, apresentar menores médias, em conjunto com o grupo 1, nos componentes galhos vivos e casca. Os valores médios de biomassa e do carbono orgânico estocado no total dos componentes, pelo grupo 2, foram maiores que os reportados em estudos anteriores com plantios de *Eucalyptus*, aos cinco anos.

Gatto et al. (2011), por exemplo, avaliaram o estoque de carbono orgânico na biomassa acima e abaixo do solo e na manta orgânica de plantações de eucalipto sob espaçamento de 3 m x 2 m, localizadas em cinco regiões do Centro-Leste do Estado de Minas Gerais, e estimaram na região de Rio Doce, região com maior estoque no total acima do solo, estoque de carbono orgânico igual a 46,00 kg árvore⁻¹, em média, e Eloy et al. (2018) encontraram produção de biomassa aérea total igual a 105,31 kg árvore⁻¹, em plantios de eucalipto com espaçamento de 3 m x 1,5 m. Contudo, esse valor inferior pode ser atribuído ao espaçamento do plantio, pois plantios com maior densidade proporcionam menor produção por indivíduo (BERNARDO et al., 1998; NAGAR et al., 2015; SOARES et al., 2018), certamente pela maior competição entre indivíduos por recursos, em espaçamentos mais densos (TSCHIEDER et al., 2012), e essa competição gera mudanças no padrão de alocação da biomassa (CANNELL; DEWAR, 1994).

3.3 MODELAGEM ALOMÉTRICA

Nessa seção estão apresentados os resultados e discussão da qualidade das estimativas para o conjunto de ajuste/treinamento, apenas de quatro equações geradas por regressão não linear e de quatro equações geradas por RNA, para cada variável estudada. Duas dessas equações utilizam somente o dap_{cc} como variável preditora e outras duas utilizam o dap_{cc} e a h_t como variáveis preditoras. Essas equações foram escolhidas, após análise da qualidade das estimativas para o conjunto de teste.

As medidas de precisão, o teste de Shapiro e Wilk e a equação linear simples da relação entre os valores previstos e observados para o conjunto de ajuste/treinamento das demais equações estão apresentadas no APÊNDICE 4 e as medidas de precisão e o teste Qui-quadrado para o conjunto de teste das demais equações estão apresentadas no APÊNDICE 6. Já, os gráficos de resíduos das estimativas para o conjunto de ajuste/treinamento e de teste das demais equações estão apresentadas nos APÊNDICES 5 e 7, respectivamente.

3.3.1 Componente folhas

O modelo Logístico foi o único que apresentou coeficientes ajustados não significativos, entre os modelos que utilizam somente o dap_{cc} como variável independente para estimativa da biomassa seca e o estoque de carbono orgânico no componente folhas, e entre os modelos que utilizam o dap_{cc} e a h_t como variáveis independentes, o Hjelm-Johansson foi o único que apresentou todos os coeficientes significativos (TABELA 14).

TABELA 14 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Logístico	β_0	9,4271533	4,779	0,0560	4,2628146	1,828	< 0,05
	β_1	229,3083840	245,353	0,3561	262,2473617	313,125	0,4077
	β_2	0,3195900	0,119	< 0,05	0,3379978	0,122	< 0,05
Monomolecular incompleto	β_0	-0,2573416	0,121	< 0,05	-0,1312367	0,063	< 0,05
	β_1	0,1720341	0,027	< 0,05	0,1698452	0,027	< 0,05
Michaelis-Menten	β_0	-2,1030103	0,438	< 0,05	-1,0546032	0,227	< 0,05
	β_1	-25,1078197	1,644	< 0,05	-25,2882047	1,742	< 0,05
Exponencial	β_0	0,1917681	0,073	< 0,05	0,0968906	0,037	< 0,05
	β_1	0,1858793	0,023	< 0,05	0,1841085	0,023	< 0,05
Spurr	β_0	0,0001541	0,000	0,4598	0,0000830	0,000	0,4619
	β_1	1,1645254	0,153	< 0,05	1,1538724	0,153	< 0,05
Schumacher-Hall	β_0	0,0020485	0,005	0,6908	0,0011366	0,003	0,6919
	β_1	3,0434861	0,674	< 0,05	3,0300317	0,678	< 0,05
	β_2	-0,2843212	1,213	0,8159	-0,3112242	1,219	0,7998
Péllico Netto	β_0	-0,0265113	0,223	0,9060	-0,0250869	0,110	0,8211
	β_1	-0,0009157	0,031	0,9763	0,0012804	0,015	0,9331
	β_2	0,0008108	0,001	0,4394	0,0003380	0,001	0,5138
Hjelm-Johansson	β_0	1,2538882	0,309	< 0,05	0,9625412	0,246	< 0,05
	β_1	-0,0133737	0,005	< 0,05	-0,0067324	0,003	< 0,05
	β_2	0,0010707	0,000	< 0,05	0,0005356	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e pvalue é a significância dos coeficientes estimados.

O modelo Logístico, quando ajustado para estimar a biomassa seca e o estoque de carbono no componente folhas, exibiu estimativas com melhores qualidades entre todos os modelos, inclusive quando estas foram comparadas as dos modelos que utilizam o dap_{cc} e a h_t como variáveis independentes, cujo destaque cabe ao modelo Schumacher-Hall em ambas variáveis (TABELA 15).

TABELA 15 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

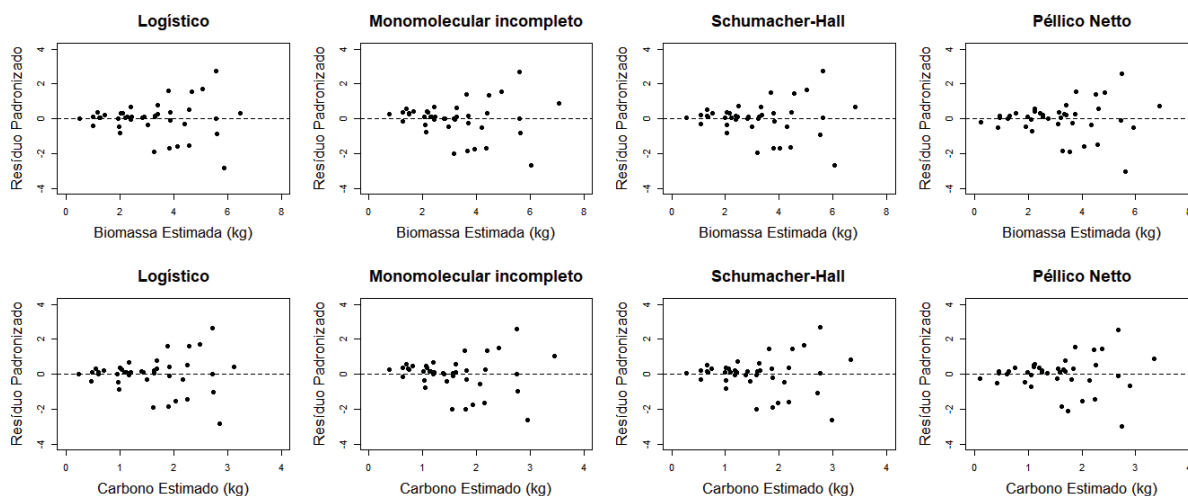
Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	1,007989	31,84	0,8331	0,9085	< 0,05	$y = 0,691314x + 0,980164$
	Monomolecular incompleto	1,022510	32,30	0,8283	0,9192	< 0,05	$y = 0,663296x + 1,088948$
	Schumacher-Hall	1,009751	31,90	0,8326	0,9154	< 0,05	$y = 0,683466x + 1,012122$
	Péllico Netto	1,022348	32,29	0,8279	0,9197	< 0,05	$y = 0,692372x + 0,966497$
Carbono	Logístico	0,497130	31,97	0,8314	0,9156	< 0,05	$y = 0,689412x + 0,483807$
	Monomolecular incompleto	0,506712	32,59	0,8248	0,9234	< 0,05	$y = 0,654908x + 0,549027$
	Schumacher-Hall	0,499414	32,12	0,8298	0,9213	< 0,05	$y = 0,676502x + 0,509061$
	Péllico Netto	0,505358	32,50	0,8252	0,9272	< 0,05	$y = 0,688602x + 0,480179$

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Campos e Leite (2006) salientam que resíduos com distribuição normal é interessante pois está intimamente relacionada à precisão e nenhuma das estimativas apresentou resíduos com tal distribuição, justificando os altos valores de REQM. Ounban et al. (2016) ajustaram o modelo de Spurr para estimar a biomassa seca das folhas produzida por árvore de *Eucalyptus camaldulensis* implantadas na Tailândia e obtiveram r_{yy} igual a 0,84, similar aos desta pesquisa. No geral, as distribuições residuais das estimativas da biomassa seca e do estoque de carbono no componente folhas foram semelhantes (FIGURA 5).

FIGURA 5 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

A equação derivada do modelo Péllico Netto foi a única que estimou a biomassa seca desse componente com um resíduo padronizado inferior a -3, mas percebe-se nas estimativas de todas as equações que houve heterocedasticidade na distribuição residual, por não haver distribuição homogênea ao longo de toda amplitude da variável estimada.

A distribuição dos pontos ficou próxima de zero, somente, até a metade do valor estimado, por isso, a ponderação das variáveis ou, com base nos resultados de Diédhiou et al. (2017), utilizar o diâmetro médio da copa como variável preditora, podem ser boas alternativas para tornar os resíduos homocedásticos.

A inclusão da h_t na camada de entrada das redes treinadas para estimar a biomassa seca e o estoque de carbono no componente folhas não melhorou as estimativas, pois, como se nota na TABELA 16 a REQM dessas redes são maiores, os r_{yy} estão mais distantes de 1 e estas não apresentam resíduos com distribuição normal.

TABELA 16 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

(continua)

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	pvalue	
Biomassa	11-6-1	75	0,649649	20,52	0,9353	0,9667	0,2821	$y = 0,839200x + 0,472248$
	11-5-1	63	0,675181	21,33	0,9297	0,9492	0,0709	$y = 0,829145x + 0,514948$
	12-5-1	104	0,676383	21,36	0,9304	0,9433	< 0,05	$y = 0,813341x + 0,568584$
	12-6-1	84	0,707724	22,35	0,9247	0,9203	< 0,05	$y = 0,785211x + 0,656595$

TABELA 16 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

(conclusão)

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Carbono	11-6-1	75	0,315566	20,30	0,9366	0,9711	0,3883	$y = 0,844625x + 0,223845$
	11-5-1	65	0,327860	21,09	0,9313	0,9529	0,0951	$y = 0,832209x + 0,246574$
	12-5-1	104	0,331913	21,35	0,9303	0,9409	< 0,05	$y = 0,814318x + 0,278733$
	12-6-1	84	0,348784	22,43	0,9239	0,9126	< 0,05	$y = 0,785662x + 0,323078$


FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As melhores redes neurais artificiais diminuíram a REQM das estimativas de biomassa seca do componente folhas de 31,84% para 20,52% e a REQM das estimativas de estoque de carbono no componente folhas de 31,97% para 20,30%, em comparação com a melhor equação; já, no r_{yy} verificou-se uma superioridade de aproximadamente 12,2%. Além disso, o coeficiente linear ficou mais próximo de zero e o coeficiente angular mais próximo de um; e apresentaram resíduos com distribuição normal, comprovando, assim, que as estimativas feitas para o conjunto de treinamento por este método, para o componente folhas, estão mais precisas.

As distribuições residuais das redes treinadas somente com dap_{cc} e materiais genéticos para estimar a biomassa seca e o estoque de carbono no componente folhas ficaram semelhantes entre si, assim como as distribuições residuais das redes treinadas com a inclusão da h_t (FIGURA 6).

FIGURA 6 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

Apesar de os resíduos indicarem que não houve, ainda, estimativas com boa precisão, as dispersões das redes que utilizam somente o dap_{cc} na camada de entrada, mostraram pontos mais bem distribuídos em torno da linha zero, com menor heterocedasticidade para as estimativas dos maiores valores, mas com uma subestimativa discrepante.

Contrariando o esperado, as estimativas da biomassa seca e do estoque de carbono orgânico nos indivíduos separados para o conjunto de teste, com as equações ajustadas por regressão não linear, apresentaram-se mais precisas em comparação com a precisão do ajuste; já nas estimativas feitas pelas redes neurais artificiais não foi observada maior precisão (TABELA 17).

TABELA 17 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Regressão não linear	Logístico	0,805127	25,50	0,8461	3,7183	0,9999
		Schumacher-Hall	0,812133	25,72	0,8434	3,8523	0,9999
	Rede neural artificial	11-6-1	0,722192	22,87	0,8833	3,1000	1,0000
		12-6-1	0,820135	25,98	0,8430	4,0701	0,9999
Carbono	Regressão não linear	Logístico	0,403302	25,89	0,8486	1,9090	1,0000
		Schumacher-Hall	0,411391	26,41	0,8433	2,0299	1,0000
	Rede neural artificial	11-6-1	0,346440	22,24	0,8934	1,4626	1,0000
		12-6-1	0,400337	25,70	0,8520	1,9978	1,0000

FONTE: O autor (2019).

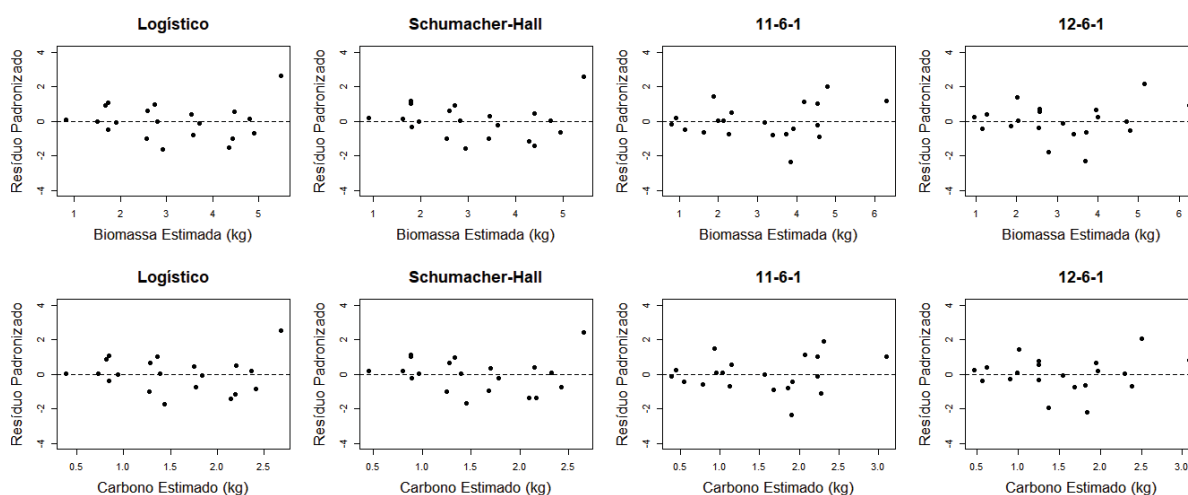
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

As medidas de qualidade do teste confirmam que apenas o dap_{cc} foi um bom preditor da biomassa seca e do estoque de carbono no componente folhas, devido as estimativas das equações oriundas do modelo logístico e da rede treinada apenas com dap_{cc} e materiais genéticos na camada de entrada, mostrarem-se mais precisas ao comparar as precisões dentro do método.

Mganga (2016) e Shahrokhzadeh et al. (2015) chegaram a mesma conclusão para estimativa do carbono foliar em *Pseudolachnostylis maprouneifolia* e da

biomassa seca produzida no componente folhas das espécies *Carpinus betulus* e *Quercus castaneafolia*, respectivamente. Os resíduos das estimativas da biomassa seca e o estoque de carbono para o conjunto de teste estão apresentados graficamente na FIGURA 7.

FIGURA 7 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

A análise gráfica dos resíduos foi um critério decisivo para escolha do melhor método preditivo, pois permitiu verificar oscilações das estimativas em toda amplitude de dados, e a partir dela, observou-se resíduos com distribuição balanceada, mas afastados do valor zero, justificando os valores das REQM acima de 20%.

Diante do exposto, as equações oriundas do modelo Logístico e da rede neural artificial com arquitetura 11-6-1 ajustaram-se com maior precisão aos dados amostrados de biomassa seca e do estoque de carbono orgânico, comprovadas pelas melhores medidas de precisão e pela distribuição residual semelhante, todavia, as estimativas feitas pela rede neural artificial foram mais precisas em ambas variáveis. Devido a isso, recomenda-se utilizar a equação com os pesos e com os *bias* obtidos no treinamento para estimar ambas variáveis. Equações que utilizam somente o dap_{cc} como variável preditora são importantes, pois, a altura é uma variável que se obtém, no campo, com maior dificuldade e com maiores erros de medição, quando comparada ao dap_{cc} .

3.3.2 Componente galhos vivos

Novamente, somente o modelo Logístico, apresentou coeficientes ajustados não significativos e somente o modelo Hjelm-Johansson apresentou todos os coeficientes ajustados significativos, entre os modelos que utilizam, respectivamente, o dap_{cc} e o dap_{cc} mais h_t como variáveis independentes, ao serem ajustados para estimar a biomassa seca e o estoque de carbono orgânico no componente galhos vivos (TABELA 18).

TABELA 18 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Logístico	β_0	42,2009776	99,196	0,6730	26,2349753	100,132	0,7948
	β_1	272,7342878	422,614	0,5227	357,0174683	1067,165	0,7399
	β_2	0,2247821	0,077	< 0,05	0,2152958	0,078	< 0,05
Monomolecular incompleto	β_0	-0,2665057	0,090	< 0,05	-0,1134379	0,040	< 0,05
	β_1	0,1858351	0,019	< 0,05	0,1860147	0,020	< 0,05
Michaelis-Menten	β_0	-2,4701466	0,337	< 0,05	-1,0472203	0,145	< 0,05
	β_1	-24,2197523	0,928	< 0,05	-24,1683443	0,938	< 0,05
Exponencial	β_0	0,2107485	0,060	< 0,05	0,0897981	0,026	< 0,05
	β_1	0,1968961	0,017	< 0,05	0,1970233	0,017	< 0,05
Spurr	β_0	0,0001041	0,000	0,3503	0,0000427	0,000	0,3601
	β_1	1,2404861	0,120	< 0,05	1,2452438	0,123	< 0,05
Schumacher-Hall	β_0	0,0061004	0,011	0,5847	0,0015090	0,003	0,6035
	β_1	3,5339739	0,504	< 0,05	3,3980136	0,523	< 0,05
	β_2	-0,9764348	0,891	0,2800	-0,6834953	0,932	0,4677
Péllico Netto	β_0	0,2699330	0,222	0,2318	0,1198151	0,097	0,2239
	β_1	-0,0443789	0,031	0,1542	-0,0195538	0,013	0,1503
	β_2	0,0025489	0,001	< 0,05	0,0011081	0,000	< 0,05
Hjelm-Johansson	β_0	1,6657905	0,178	< 0,05	1,2057415	0,140	< 0,05
	β_1	-0,0232937	0,004	< 0,05	-0,0102706	0,002	< 0,05
	β_2	0,0015903	0,000	< 0,05	0,0007022	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes ajustados das equações, e pvalue é a significância dos coeficientes estimados.

Entre os modelos que utilizam somente o dap_{cc} como variável independente para estimar a biomassa seca do componente galhos vivos, o modelo Logístico apresentou as melhores medidas de precisão e, entre os modelos que utilizam o dap_{cc} e a h_t , o modelo Schumacher-Hall apresentou as melhores medidas de precisão, superando, inclusive, o modelo Logístico. Já, entre os ajustes para estimar o estoque de carbono orgânico nesse componente, ressalta-se a elevada proximidade nas

precisões dos modelos Logístico, Monomolecular incompleto e Schumacher-Hall (TABELA 19).

TABELA 19 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	0,981317	23,59	0,8999	0,9669	0,2849	$y = 0,811470x + 0,782110$
	Monomolecular incompleto	0,982293	23,61	0,8997	0,9626	0,2060	$y = 0,808530x + 0,797763$
	Schumacher-Hall	0,974103	23,41	0,9016	0,9738	0,4704	$y = 0,823915x + 0,718877$
	Hjelm-Johansson	0,986226	23,70	0,8989	0,9848	0,8569	$y = 0,807283x + 0,803206$
Carbono	Logístico	0,432337	24,33	0,8942	0,9686	0,3244	$y = 0,800292x + 0,354519$
	Monomolecular incompleto	0,432471	24,34	0,8942	0,9678	0,3047	$y = 0,799928x + 0,355294$
	Schumacher-Hall	0,432836	24,36	0,8941	0,9739	0,4736	$y = 0,812344x + 0,326535$
	Hjelm-Johansson	0,434342	24,44	0,8932	0,9850	0,8652	$y = 0,797549x + 0,360055$

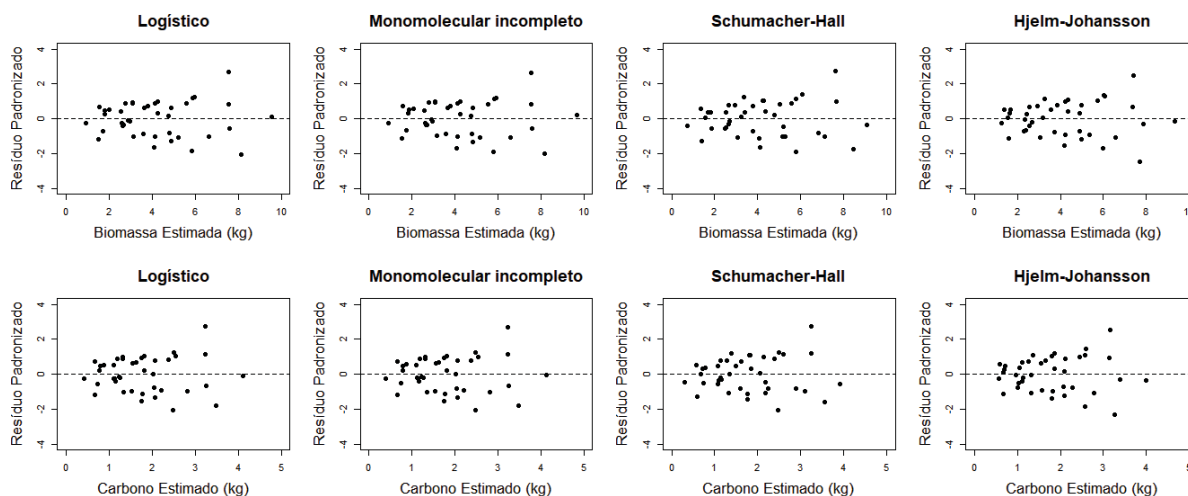
FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Sanquetta et al. (2014) ajustaram o modelo Schumacher-Hall linearizado por transformação logarítmica, em sistema simultâneo, e a estimativa da biomassa seca do componente galhos vivos de árvores de acácia negra, implantadas em duas regiões do estado do Rio Grande do Sul, foi mais precisa que a deste estudo, em contrapartida, a precisão exposta por Behling et al. (2012) foi inferior, utilizando, também, o modelo Schumacher-Hall linearizado por transformação logarítmica para estimar a biomassa seca do galhos vivos de árvores de acácia negra.

Não se nota, entre os modelos ajustados para estimar a biomassa seca e o estoque de carbono orgânico no componente galhos vivos, nenhum modelo que apresentou estimativas enviesadas (FIGURA 8), houve apenas estimativas com resíduos padronizados fora da amplitude de -2 e 2.

FIGURA 8 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

Diferentemente do que foi observado nas redes treinadas para estimativas no componente folhas, a inclusão da h_t na camada de entrada propiciou redes neurais artificiais com melhores estimativas da biomassa seca e do estoque de carbono orgânico no componente galhos vivos, contudo, entre estas, somente os resíduos das redes com seis neurônios na camada intermediária distribuíram-se normalmente, mesmo não tendo apresentado as melhores medidas de precisão (TABELA 20).

TABELA 20 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-5-1	38	0,956117	22,98	0,9056	0,9704	0,3693	$y = 0,805635x + 0,769946$
	11-6-1	51	0,946864	22,76	0,9074	0,9775	0,5991	$y = 0,814736x + 0,736836$
	12-6-1	70	0,743341	17,87	0,9451	0,9570	0,1322	$y = 0,850812x + 0,581167$
	12-4-1	84	0,739741	17,78	0,9450	0,9276	< 0,05	$y = 0,862671x + 0,552323$
Carbono	11-6-1	45	0,423911	23,86	0,8988	0,9751	0,5146	$y = 0,799223x + 0,339027$
	11-4-1	58	0,401023	22,57	0,9101	0,9433	< 0,05	$y = 0,810450x + 0,321044$
	12-4-1	79	0,340951	19,19	0,9361	0,9279	< 0,05	$y = 0,849630x + 0,260239$
	12-6-1	54	0,363754	20,47	0,9276	0,9572	0,1343	$y = 0,820134x + 0,300155$


FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Foi difícil comparar as precisões obtidas pelas redes treinadas nesse estudo com as precisões de outras pesquisas desenvolvidas no Brasil ou no mundo, devido à escassez de resultados. Mas, as precisões indicadas para o conjunto de treinamento

foram superiores as precisões das equações alométricas desenvolvidas por regressão não linear; tal superioridade pode ser atribuída a inclusão dos materiais genéticos na camada de entrada. Ainda, é notório, também, resíduos com distribuição não enviesada nas estimativas das redes treinadas (FIGURA 9).

FIGURA 9 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

Os resíduos das estimativas feitas pelas redes treinadas apresentaram-se balanceados, assim como os resíduos das estimativas feitas pelas equações, porém, os gráficos residuais das redes neurais artificiais parecem visualmente conduzir a uma estimativa da biomassa seca e do estoque de carbono mais precisa em toda amplitude, em comparação com os gráficos das equações.

Menor precisão foi observada nas estimativas da biomassa seca e do carbono orgânico estocado nos indivíduos separados para o conjunto de teste em comparação com a precisão das estimativas para o conjunto de ajuste/treinamento, como se esperava, pois, foram utilizados conjuntos de dados diferentes (TABELA 21).

TABELA 21 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

(continua)

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}\hat{y}}$	Qui-Quadrado	
			kg	(%)		χ^2	pvalue
Biomassa	Regressão não linear	Logístico	1,174065	27,79	0,8171	6,2904	0,9971
		Schumacher-Hall	1,056224	25,00	0,8542	5,2371	0,9992

TABELA 21 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

(conclusão)

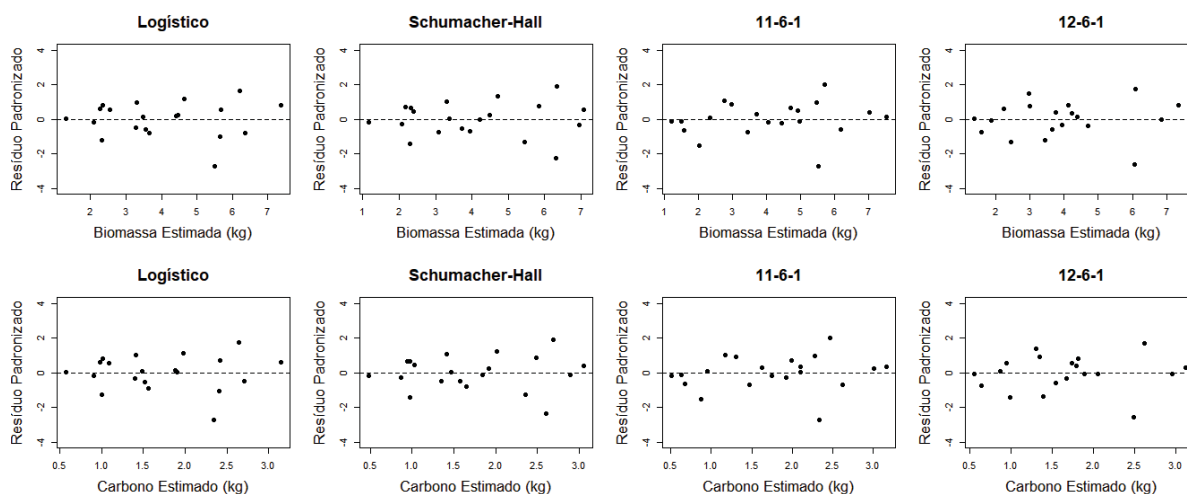
Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Rede neural artificial	11-6-1	1,175664	27,83	0,8172	7,1350	0,9935
		12-6-1	1,019160	24,12	0,8657	5,2443	0,9992
Carbono	Regressão não linear	Logístico	0,512062	28,38	0,8084	2,8322	1,0000
		Schumacher-Hall	0,479179	26,56	0,8340	2,5283	1,0000
	Rede neural artificial	11-6-1	0,516125	28,61	0,8063	3,2158	1,0000
		12-6-1	0,484919	26,88	0,8310	2,9131	1,0000

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

Mesmo que as estimativas com os dados de teste tenham sido menos precisas, o teste X^2 indicou que houve aderência entre os valores observados e estimados por ambos os métodos. Ainda, a dispersão dos resíduos padronizados das estimativas da biomassa seca e do estoque de carbono orgânico no componente galhos vivos dos indivíduos separados para teste, apresentou-se balanceada, indicando que não houve tendência, mas todas as equações estimaram um valor com resíduo abaixo de -2, esperava-se que houvesse heterogeneidade na distribuição dos resíduos, pois no ajuste e no treinamento houve a preponderância de árvores pequenas e grandes (FIGURA 10).

FIGURA 10 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

O ajuste do modelo Schumacher-Hall gerou estimativas com melhores medidas de precisão, mas dois coeficientes foram estimados com significância superior a 5%, devido a isso, a equação gerada pode não ser confiável para ser utilizada em outros sítios, pois, possivelmente, irá gerar erros de estimativas elevados, indica Sileshi (2014).

Os erros nesses coeficientes e nos coeficientes das equações ajustadas para estimar ambas variáveis nos demais componentes estão provavelmente relacionados com as diferentes formas de crescimento dos indivíduos entre e dentro dos materiais genéticos, pois na modelagem foi empregada dados de multiespécies e a variância existente não foi contabilizada para ajuste. Niklas e Spatz (2004) salientam que equações generalizadas que ignoram as espécies podem apresentar boas medidas de precisão, mas que haverá, ainda assim, variação da biomassa entre e dentro das espécies como consequência da interação genótipo-ambiente.

Linearizar o modelo por transformação logarítmica e ajustar os coeficientes por mínimos quadrados ordinários poderia solucionar a inflação do erro padrão dos coeficientes, pois Soares e Oliveira (2002) ajustaram o modelo Schumacher-Hall linearizado para estimar a biomassa dos galhos de árvores de um povoamento de *Eucalyptus grandis* W. Hill ex-Maiden, localizado no município de Viçosa, Minas Gerais, Brasil e obtiveram coeficientes significativos.

Por isso, a equação oriunda da rede treinada com 12 neurônios na camada de entrada e seis neurônios na camada intermediária, além de ter sido considerada a

mais precisa na estimativa da biomassa seca, por apresentar melhores medidas de precisão, também foi considerada a melhor para estimar o estoque de carbono orgânico.

3.3.3 Componente galhos secos

Diferentemente do que foi observado nos ajustes anteriores, todos os modelos, incluindo os que utilizam o dap_{cc} ou o dap_{cc} mais h_t como variáveis independentes, quando ajustados para estimar a biomassa seca e o estoque de carbono orgânico no componente galhos secos, apresentaram pelo menos um coeficiente ajustado não significativo (TABELA 22).

TABELA 22 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	Pvalue	Valor Estimado	Erro padrão	Pvalue
Logístico	β_0	10,0427940	32,718	0,7606	6,0149389	29,659	0,8404
	β_1	30,0661676	44,529	0,5037	35,1102156	109,366	0,7500
	β_2	0,1658003	0,234	0,4837	0,1526783	0,230	0,5118
Monomolecular incompleto	β_0	-1,1879449	1,352	0,3853	-0,5288359	0,593	0,3780
	β_1	0,0817331	0,052	0,1233	0,0835095	0,052	0,1136
Michaelis-Menten	β_0	-3,9759267	2,966	0,1880	-1,7864171	1,294	0,1756
	β_1	-35,9459463	14,673	< 0,05	-35,3714731	13,818	< 0,05
Exponencial	β_0	0,4927393	0,282	0,0889	0,2238757	0,128	0,0892
	β_1	0,1164292	0,036	< 0,05	0,1175813	0,036	< 0,05
Spurr	β_0	0,0108120	0,021	0,6109	0,0046869	0,009	0,6115
	β_1	0,6546806	0,225	< 0,05	0,6622325	0,226	< 0,05
Schumacher-Hall	β_0	1,8951465	5,842	0,7475	0,7679424	2,385	0,7493
	β_1	2,9984842	1,063	< 0,05	2,9802414	1,064	< 0,05
	β_2	-2,4698974	1,696	0,1538	-2,4116292	1,703	0,1651
Péllico Netto	β_0	0,0256038	0,325	0,9377	0,0172853	0,150	0,9090
	β_1	0,0024820	0,045	0,9560	0,0003379	0,021	0,9870
	β_2	0,0002780	0,002	0,8552	0,0001577	0,001	0,8227
Hjelm-Johansson	β_0	1,6434801	0,269	< 0,05	1,2292393	0,210	< 0,05
	β_1	-0,0127908	0,006	0,0504	-0,0063105	0,003	0,0541
	β_2	0,0007269	0,000	< 0,05	0,0003623	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e p_{value} é a significância dos coeficientes estimados.

Os modelos ajustados para estimativa da biomassa seca e do estoque de carbono orgânico no componente galhos secos apresentaram, no geral, os piores resultados, com maiores percentuais de REQM e menores $r_{yy}^{\hat{}}$, além de apresentarem

o coeficiente linear e o coeficiente angular da equação linear simples da relação entre os valores previstos e observados mais distantes dos seus ideais (TABELA 23).

TABELA 23 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Michaelis-Menten	1,455612	52,10	0,4924	0,9501	0,0763	$y = 0,238457x + 2,131485$
	Exponencial	1,457068	52,16	0,4909	0,9488	0,0691	$y = 0,237314x + 2,134308$
	Schumacher-Hall	1,414760	50,64	0,5333	0,9677	0,3038	$y = 0,279232x + 2,018726$
	Hjelm-Johansson	1,451757	51,97	0,4964	0,9620	0,1963	$y = 0,243757x + 2,118944$
Carbono	Michaelis-Menten	0,672713	52,06	0,4952	0,9546	0,1093	$y = 0,242220x + 0,980499$
	Exponencial	0,673313	52,11	0,4939	0,9536	0,1011	$y = 0,240770x + 0,982420$
	Schumacher-Hall	0,655092	50,70	0,5332	0,9703	0,3677	$y = 0,279679x + 0,932825$
	Hjelm-Johansson	0,673776	52,15	0,4928	0,9644	0,2363	$y = 0,242212x + 0,921190$

FONTE: O autor (2019).

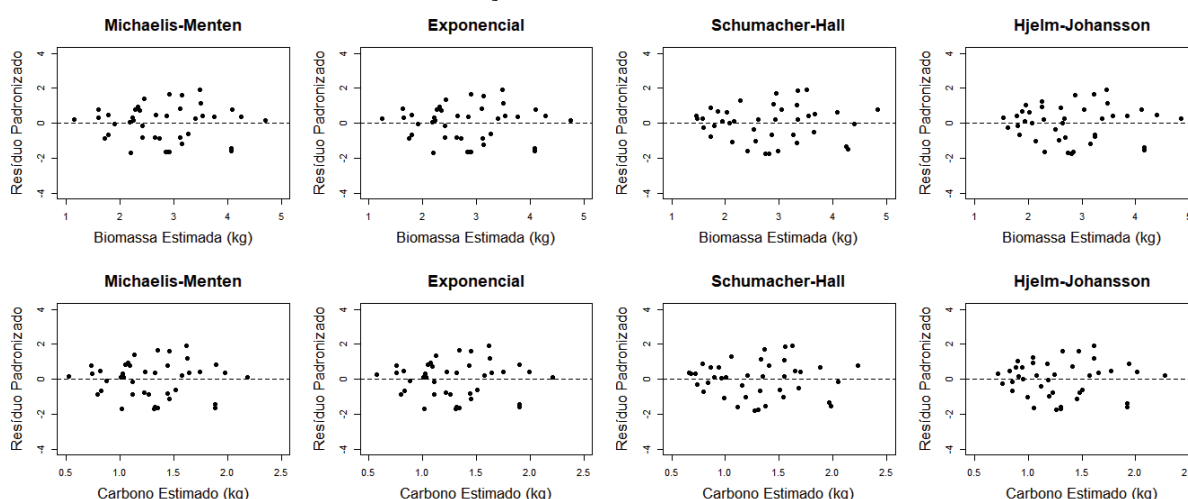
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

A equação oriunda do modelo Schumacher-Hall apresentou os resultados menos imprecisos, em ambos ajustes das variáveis, em contrapartida, as equações oriundas dos modelos Exponencial e Hjelm-Johansson apresentaram-se mais imprecisas ao serem ajustadas para estimar a biomassa seca e o estoque de carbono orgânico, respectivamente.

Os componentes galhos são, geralmente, mais variáveis em relação a outros componentes da árvore, pois sofrem maiores influências de fatores bióticos e abióticos, destacam Ant3nio et al. (2007). Menor eficiência das equações para esse componente era esperada, pois variáveis dos componentes oriundos da ramificação, como por exemplo os galhos, são sempre difíceis de se prever com precisão similar à do lenho ou a do total (MIKSYS et al., 2007). Návar (2009) indica que a menor precisão das estimativas nesse componente pode ser atribuída ao tempo curto de vida, devido aos intempéries, aos herbívoros e a competição.

Todos os modelos, quando ajustados para estimar a biomassa seca e o estoque de carbono orgânico no componente galhos secos, apresentaram resíduos padronizados bem distribuídos e concentrados entre -2 e 2 (FIGURA 11).

FIGURA 11 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

Apesar da boa distribuição, os resíduos padronizados desse componente estão mais distantes de zero, comprovando que para muitos valores da(s) variável(s) preditor(a)s houve baixa precisão na estimativa. As redes treinadas para estimativas da biomassa seca e do estoque de carbono orgânico no componente galhos secos apresentaram-se, em comparação com os demais componentes, menos precisas, com maiores REQM percentuais (TABELA 24).

TABELA 24 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-3-1	17	1,169311	41,85	0,7173	0,9560	0,1223	$y = 0,472871x + 1,463705$
	11-6-1	51	1,029238	36,84	0,7932	0,9747	0,4999	$y = 0,559354x + 1,206069$
	12-3-1	88	0,931848	33,36	0,8359	0,9630	0,2126	$y = 0,618607x + 1,062654$
	12-5-1	81	0,959066	34,33	0,8245	0,9510	0,0819	$y = 0,603779x + 1,080591$
Carbono	11-3-1	16	0,535260	41,43	0,7252	0,9566	0,1281	$y = 0,481340x + 0,665608$
	11-6-1	51	0,473360	36,64	0,7964	0,9763	0,5563	$y = 0,564291x + 0,551318$
	12-3-1	88	0,427086	33,05	0,8394	0,9620	0,1953	$y = 0,625708x + 0,482360$
	12-5-1	81	0,442022	34,21	0,8260	0,9525	0,0924	$y = 0,608666x + 0,492976$

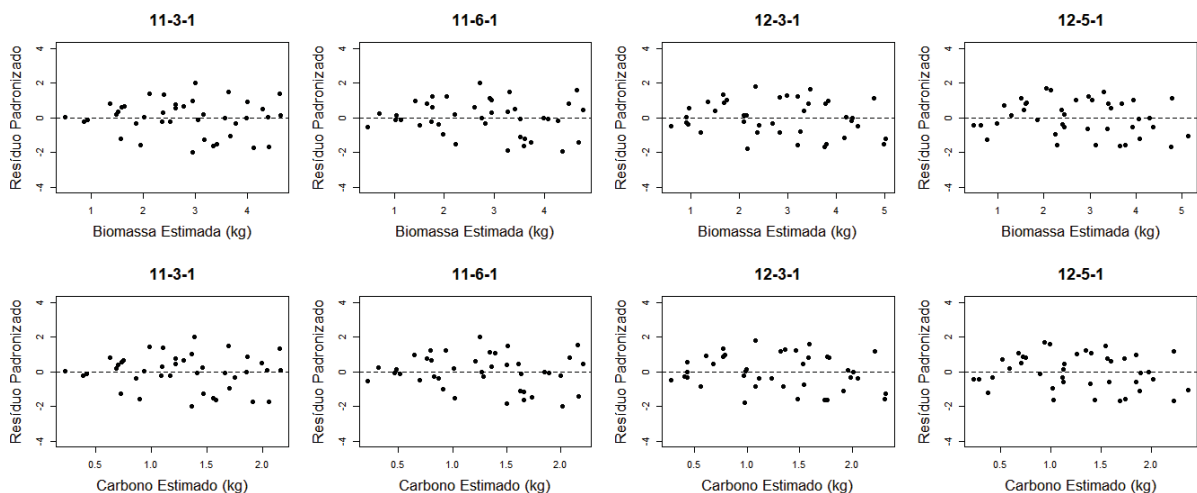
FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Nesse componente ocorreram as maiores diferenças de precisão, no geral, ao comparar as precisões redes treinadas com as das equações ajustadas, para estimar ambas variáveis no componente galhos secos. As melhores redes neurais diminuíram a REQM das estimativas de biomassa seca de 50,64% para 33,36% e a REQM das estimativas de estoque de carbono de 50,70% para 33,05%, ao comparar com as melhores equações, além disso, o $r_{\hat{y}\hat{y}}$ saiu de 0,53 para 0,84, superioridade de aproximadamente 60%.

Os resíduos das redes treinadas para estimar a biomassa seca e o estoque de carbono no componente galhos secos apresentaram-se, ainda, com distribuição mais homogênea e mais compacta, dentro do intervalo de -2 e 2, o que comprova que as estimativas feitas por este método ficaram mais próximas das observadas (FIGURA 12).

FIGURA 12 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

A rede treinada com cinco neurônios na camada intermediária e com o dap_{cc} , a h_t e os materiais genéticos na camada de entrada, gerou a equação que estima a biomassa seca e do estoque de carbono orgânico nos indivíduos separados para teste com maior precisão, baseando-se nas medidas que indicam a qualidade das estimativas (TABELA 25).

TABELA 25 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		χ^2	pvalue
Biomassa	Regressão não linear	Exponencial	1,518488	72,30	0,2687	14,9718	0,7244
		Hjelm-Johansson	1,514106	72,09	0,2782	14,9886	0,7233
	Rede neural artificial	11-6-1	1,304246	62,09	0,6135	10,4813	0,9401
		12-5-1	1,260035	59,99	0,6755	9,6143	0,9618
Carbono	Regressão não linear	Exponencial	0,706510	72,38	0,2658	6,9932	0,9942
		Hjelm-Johansson	0,705812	72,31	0,2614	7,0391	0,9940
	Rede neural artificial	11-3-1	0,600352	61,50	0,6176	4,9756	0,9995
		12-5-1	0,581444	59,57	0,6769	4,4220	0,9998

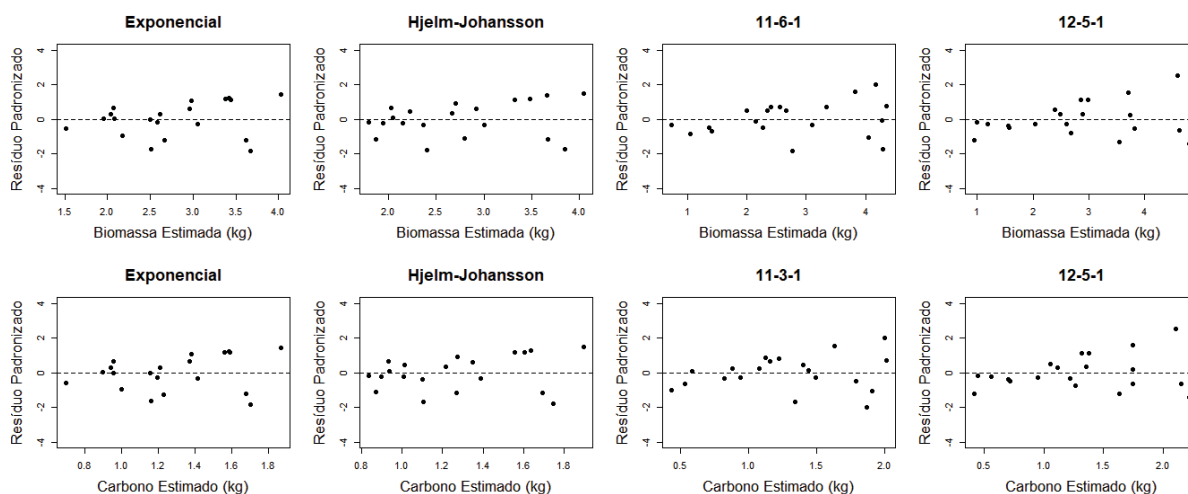
FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, χ^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

Com exceção da rede que possui arquitetura 11-6-1 treinada para estimar a biomassa seca produzida pelo componente galhos secos, todos os demais modelos e redes neurais artificiais selecionadas como as mais precisas no teste, não foram as mais precisas no ajuste ou no treinamento. Isto comprova a importância de testar as equações com dados que possuam características populacionais semelhantes e que não foram utilizados nos processos de geração das equações.

Mesmo apresentando melhores distribuições residuais nos indivíduos separados para treinamento e as maiores precisões nas estimativas de ambos os conjuntos, nota-se que os resíduos das redes neurais artificiais selecionadas apresentaram distribuição totalmente enviesadas para os menores valores (FIGURA 13); isto é um indicativo de que pode ter ocorrido memorização dos dados de treinamento.

FIGURA 13 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Portanto, a equação obtida após ajuste do modelo Hjelms-Johansson foi considerada a que forneceu as melhores estimativas da biomassa seca e do estoque de carbono orgânico, apesar de não ter fornecido as melhores medidas de precisão.

3.3.4 Componente casca

Os modelos Monomolecular incompleto, Michaelis-Menten, Exponencial e Hjelms-Johansson, quando ajustados para estimar a biomassa seca e o estoque de carbono orgânico no componente casca, apresentaram todos os coeficientes ajustados significativos (TABELA 26).

TABELA 26 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA

(continua)

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Logístico	β_0	14,2245808	2,631	< 0,05	5,7750404	1,025	< 0,05
	β_1	143,4850628	117,804	0,2309	175,8019842	161,210	0,2825
	β_2	0,3375839	0,080	< 0,05	0,3555173	0,087	< 0,05
Monomolecular incompleto	β_0	-1,4052076	0,463	< 0,05	-0,5736165	0,202	< 0,05
	β_1	0,1200046	0,017	< 0,05	0,1211492	0,019	< 0,05
Michaelis-Menten	β_0	-6,9426693	1,349	< 0,05	-2,8810943	0,596	< 0,05
	β_1	-29,7223548	2,542	< 0,05	-29,6556089	2,692	< 0,05
Exponencial	β_0	0,8050316	0,180	< 0,05	0,3307057	0,079	< 0,05
	β_1	0,1443469	0,014	< 0,05	0,1452879	0,015	< 0,05

TABELA 26 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA

(conclusão)

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Spurr	β_0	0,0037339	0,003	0,1927	0,0015301	0,001	0,2258
	β_1	0,8859746	0,087	< 0,05	0,8879910	0,093	< 0,05
Schumacher-Hall	β_0	0,0285030	0,039	0,4717	0,0161643	0,024	0,4967
	β_1	2,3536843	0,386	< 0,05	2,4759464	0,413	< 0,05
	β_2	-0,2700404	0,683	0,6949	-0,4750899	0,727	0,5175
Péllico Netto	β_0	-0,3141319	0,292	0,2897	-0,1522431	0,131	0,2523
	β_1	0,0475588	0,040	0,2441	0,0225982	0,018	0,2169
	β_2	-0,0003386	0,001	0,8049	-0,0002293	0,001	0,7087
Hjelm-Johansson	β_0	1,6794023	0,245	< 0,05	1,2106220	0,201	< 0,05
	β_1	-0,0192103	0,006	< 0,05	-0,0084963	0,003	< 0,05
	β_2	0,0016842	0,000	< 0,05	0,0007328	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e pvalue é a significância dos coeficientes estimados.

O modelo Monomolecular incompleto exibiu, entre os modelos que utiliza somente o dap_{cc} como variável independente, estimativas com melhores qualidades (TABELA 27), mas no geral o modelo Schumacher-Hall apresentou melhores medidas de precisão, entretanto, nenhum dos modelos apresentam resíduos distribuídos normalmente.

TABELA 27 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(continua)

Variável	Modelo	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
		kg	(%)		SW	pvalue	
Biomassa	Monomolecular incompleto	1,345729	19,29	0,8915	0,9175	< 0,05	$y = 0,756508x + 1,743730$
	Michaelis-Menten	1,386926	19,88	0,8865	0,9103	< 0,05	$y = 0,720635x + 2,022740$
	Spurr	1,348978	19,34	0,8900	0,9275	< 0,05	$y = 0,775529x + 1,585980$
	Schumacher-Hall	1,297306	18,60	0,8989	0,9314	< 0,05	$y = 0,785837x + 1,520772$
Carbono	Monomolecular incompleto	0,600846	20,68	0,8805	0,8848	< 0,05	$y = 0,734574x + 0,792131$
	Michaelis-Menten	0,618833	21,30	0,8752	0,8787	< 0,05	$y = 0,697261x + 0,913404$
	Spurr	0,605630	20,84	0,8774	0,8863	< 0,05	$y = 0,748989x + 0,740379$

TABELA 27 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(conclusão)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Carbono	Schumacher-Hall	0,577219	19,87	0,8895	0,9161	< 0,05	$y = 0,767251x + 0,688895$

FONTE: O autor (2019).

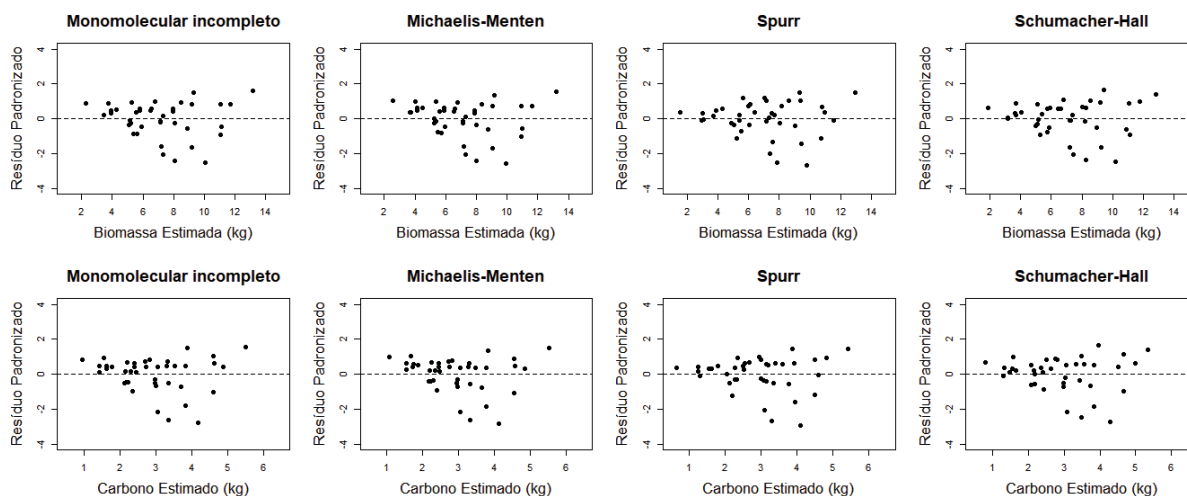
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As precisões das equações dependem muito do tamanho amostral, dos modelos utilizados em consonância com variáveis preditoras, para as condições de crescimento dos indivíduos. Devido a isso, comparar precisões das estimativas com precisões de equações desenvolvidas a diferentes espécies e locais pode não ser relevante, devido aos diferentes atributos biofísicos.

Mas, as precisões das equações aqui testadas foram similares a apresentada por Sharma et al. (2017) e superiores a apresentada por Subedi e Sharma (2012). Esses autores ajustaram modelos alométricos para estimar a biomassa produzida pela casca de árvores de *Daphne bholua* e de *Cinnamomum tamala*, na região das Colinas do Nepal e encontraram REQM iguais a 20,98% e 25,81%, respectivamente. A primeira pesquisa utilizou o dap_{cc} e uma variável de esbeltez (h_t/dap_{cc}), em $m\ cm^{-1}$, como variáveis preditoras, e a segunda utilizou o dap_{cc} e a h_t .

Apesar de não existir tendência óbvia nos resíduos padronizados dos quatro modelos ajustados para estimar a biomassa seca e o estoque de carbono na casca em toda amplitude, todas as estimativas apresentaram erros que subestimam os maiores valores observados, indicando que os modelos ajustaram-se inadequadamente a essas observações (FIGURA 14).

FIGURA 14 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

As redes treinadas com a h_t , além do dap_{cc} e dos materiais genéticos, na camada de entrada para estimar a biomassa seca e o estoque de carbono orgânico no componente casca, exibiram estimativas com melhores qualidades, e, entre estas, as que utilizam seis neurônios na camada intermediária apresentaram melhores medidas de precisão (TABELA 28).

TABELA 28 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	pvalue	
Biomassa	11-5-1	100	0,915355	13,12	0,9511	0,9655	0,2567	$y = 0,884918x + 0,779580$
	11-6-1	82	1,053924	15,11	0,9343	0,9774	0,5956	$y = 0,865383x + 0,923762$
	12-6-1	127	0,579651	8,31	0,9807	0,9826	0,7854	$y = 0,946432x + 0,375894$
	12-3-1	229	0,636719	9,13	0,9766	0,9871	0,9207	$y = 0,942273x + 0,377095$
Carbono	11-5-1	94	0,431847	14,86	0,9398	0,9675	0,2995	$y = 0,863661x + 0,380131$
	11-6-1	93	0,450141	15,49	0,9343	0,9838	0,8245	$y = 0,859051x + 0,396613$
	12-6-1	126	0,271772	9,35	0,9767	0,9864	0,9054	$y = 0,932609x + 0,190194$
	12-3-1	198	0,349694	12,04	0,9614	0,9611	0,1821	$y = 0,891949x + 0,300186$

FONTE: O autor (2019).


LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, pvalue é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As estimativas da biomassa seca e do estoque de carbono na casca foram substancialmente melhores com o uso das redes neurais artificiais treinadas, em comparação com o uso das equações, pois a REQM caiu de 18,60% para até 8,31% e de 19,87% para 9,35%, respectivamente. Ademais, as redes conseguiram realizar

estimativas que melhor se correlacionaram com os valores observados. As melhores redes treinadas para estimar a biomassa seca, apresentaram $r_{y\hat{y}}$ superiores aos obtidos por Zhao et al. (2015), além de menor REQM, em kg árvore⁻¹.

Esses autores ajustaram modelos alométricos que utilizam variáveis de copa como preditoras, além de dap_{cc} e h_t , por regressão não linear aparentemente não relacionada (NSUR), com dados de 456 árvores de *Pinus taeda* L., aos 12, 15 e 16 anos, em 114 parcelas com diferentes densidades, mas não apresentaram valor médio da variável, para comparar os valores em percentagem.

Özçelik et al. (2017) chegaram a resultados semelhantes, ao concluírem que as estimativas das redes treinadas se adequam com maior confiabilidade aos valores observados, em comparação com as equações oriundas do ajuste NSUR. As redes neurais artificiais treinadas apresentaram resíduos com distribuição menos heterogênea, pois corrigiu a tendência aparente das subestimativas observadas nas equações, todavia, algumas das estimativas, ainda, subestimaram ou superestimaram além de dois desvios (FIGURA 15).



FONTE: O autor (2019).

Nas estimativas feitas para o componente casca aos indivíduos separados para teste, a rede que utilizou o dap_{cc} , a h_t e os materiais genéticos na camada de entrada e três neurônios na camada intermediária, apresentou melhores medidas de precisão, mesmo não tendo apresentado as melhores medidas nos indivíduos do treinamento; e a rede que utilizou essas mesmas variáveis na camada de entrada e

seis neurônios na camada intermediária mostrou, também, melhores medidas de precisão ao estimar o estoque de carbono orgânico, além de, ter sido a mais precisa no treinamento (TABELA 29).

TABELA 29 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}y}$	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Regressão não linear	Monomolecular incompleto	1,086200	16,73	0,8814	3,2044	1,0000
		Schumacher-Hall	1,070595	16,49	0,8948	2,9533	1,0000
	Rede neural artificial	11-5-1	0,905831	13,95	0,9528	1,9513	1,0000
		12-3-1	0,814153	12,54	0,9718	1,6120	1,0000
Carbono	Regressão não linear	Monomolecular incompleto	0,492711	18,50	0,8683	1,5929	1,0000
		Schumacher-Hall	0,484628	18,20	0,8866	1,4747	1,0000
	Rede neural artificial	11-5-1	0,410326	15,41	0,9472	0,9673	1,0000
		12-6-1	0,380994	14,30	0,9677	0,8070	1,0000


FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, $r_{\hat{y}y}$ é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

As precisões das estimativas feitas pelas redes superaram em aproximadamente 24,0% e 21,4% as precisões das estimativas das equações desenvolvidas por regressão não linear, comparando as REQM. Li e Zhao (2013) modelaram a biomassa da casca do lenho com dados de 600 árvores de *Cunninghamia lanceolata* implantadas no sul da China por mínimos quadrados ponderados e obtiveram REQM igual a 44,21%, muito superior a todas obtidas nessa pesquisa.

As distribuições residuais apresentadas na FIGURA 16 contrapõem as precisões indicadas para estimativa da biomassa seca e do estoque de carbono orgânico na casca do lenho.

FIGURA 16 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS melhores EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Há claramente tendência nas estimativas feitas pelas redes neurais artificiais em toda amplitude, começando por subestimação e passando para superestimação, indicando que os erros estão possivelmente correlacionados, mesmo que estas tenham apresentados as melhores medidas de precisão. Devido a isso e levando em consideração as significâncias dos coeficientes ajustados, bem como o número de variáveis preditoras, a equação oriunda do modelo Monomolecular incompleto foi considerada a melhor para estimativas dessas variáveis, mesmo que seus resíduos não indiquem um ajuste ideal.

3.3.5 Componente lenho

Todos os modelos que utilizam somente o dap_{cc} como variável independente para estimar a biomassa seca e o estoque de carbono orgânico no componente lenho, expuseram coeficientes ajustados significativos, ao contrário do observado para o componente galhos secos, além disso, o modelo Spurr apresentou todos os coeficientes ajustados significativos, diferentemente do que foi observado nos ajustes anteriores, bem como, o modelo Hjelm-Johansson (TABELA 30).

TABELA 30 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	p _{value}	Valor Estimado	Erro padrão	p _{value}
Logístico	β_0	255,1005938	58,010	< 0,05	111,6937592	25,028	< 0,05
	β_1	98,7653797	19,996	< 0,05	96,9521185	19,781	< 0,05
	β_2	0,2538316	0,033	< 0,05	0,2537580	0,033	< 0,05
Monomolecular incompleto	β_0	-10,1317318	1,443	< 0,05	-4,5740787	0,651	< 0,05
	β_1	0,1443513	0,008	< 0,05	0,1432343	0,008	< 0,05
Michaelis-Menten	β_0	-60,6340515	4,614	< 0,05	-27,0645805	2,066	< 0,05
	β_1	-26,7391384	0,744	< 0,05	-26,8279313	0,754	< 0,05
Exponencial	β_0	6,7243619	0,743	< 0,05	3,0183940	0,332	< 0,05
	β_1	0,1629555	0,007	< 0,05	0,1620700	0,007	< 0,05
Spurr	β_0	0,0131736	0,004	< 0,05	0,0061616	0,002	< 0,05
	β_1	1,0196878	0,032	< 0,05	1,0133157	0,032	< 0,05
Schumacher-Hall	β_0	0,0113023	0,006	0,0841	0,0054792	0,003	0,0844
	β_1	1,9981782	0,144	< 0,05	1,9950383	0,145	< 0,05
	β_2	1,1044640	0,269	< 0,05	1,0782890	0,270	< 0,05
Péllico Netto	β_0	-0,3761178	1,187	0,7532	-0,1962691	0,527	0,7115
	β_1	0,0401078	0,163	0,8072	0,0233357	0,072	0,7489
	β_2	0,0146348	0,006	< 0,05	0,0062444	0,002	< 0,05
Hjelm-Johansson	β_0	3,0032792	0,355	< 0,05	2,2553710	0,265	< 0,05
	β_1	-0,1503733	0,021	< 0,05	-0,0688648	0,010	< 0,05
	β_2	0,0179483	0,001	< 0,05	0,0080380	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e p_{value} é a significância dos coeficientes estimados.

Maior discrepância entre a precisão dos modelos que utilizam somente o dap_{cc} e os modelos que utilizam dap_{cc} e h_t como variáveis independentes foi observada nos ajustes feitos para a biomassa seca e para o estoque de carbono orgânico no componente lenho (TABELA 31). A REQM e os coeficientes da equação linear simples que explicam a relação entre os valores previstos e observados separam claramente estes modelos.

TABELA 31 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(continua)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Monomolecular incompleto	7,083486	9,10	0,9771	0,9787	0,6396	$y = 0,930970x + 5,698513$
	Michaelis-Menten	7,795948	10,01	0,9733	0,9591	0,1564	$y = 0,898140x + 8,579024$
	Schumacher-Hall	5,444262	6,99	0,9864	0,9792	0,6583	$y = 0,969735x + 2,400216$
	Hjelm-Johansson	5,675453	7,29	0,9852	0,9772	0,5875	$y = 0,969072x + 2,429633$

TABELA 31 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(conclusão)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Carbono	Monomolecular incompleto	3,123682	9,06	0,9771	0,9672	0,2918	$y = 0,930667x + 2,533248$
	Michaelis-Menten	3,432805	9,96	0,9733	0,9629	0,2097	$y = 0,898322x + 3,788316$
	Schumacher-Hall	2,417695	7,01	0,9861	0,9873	0,9254	$y = 0,968987x + 1,090193$
	Hjelm-Johansson	2,529176	7,34	0,9848	0,9867	0,9115	$y = 0,968375x + 1,099854$

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

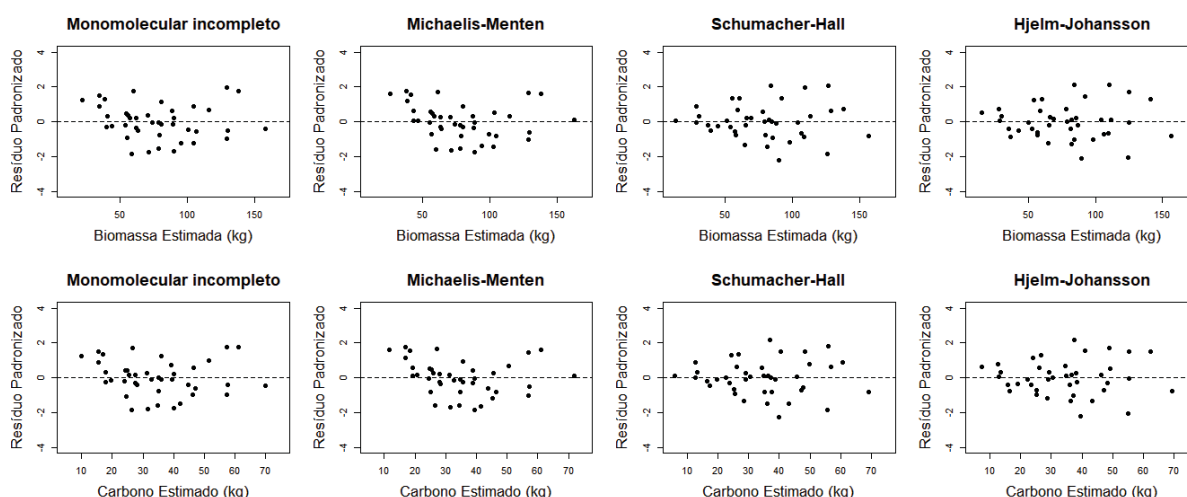
A diferença da REQM entre o melhor modelo que utiliza somente o dap_{cc} (Monomolecular incompleto) e o melhor modelo que inclui a h_t (Schumacher-Hall) foi de, no mínimo, 2,05%, além disso, os coeficientes da equação linear foram melhores. Do ponto de vista biológico, espera-se que a altura seja uma variável determinante da biomassa do lenho, e quando esta foi incluída como preditora, além do dap_{cc} por Picard et al. (2015), a estimativa da biomassa, também, melhorou substancialmente; sua utilização incorpora a vantagem de aumentar a aplicabilidade da equação em diferentes locais (KETTERINGS et al., 2001), pois na presença de duas árvores com mesmo diâmetro, a altura atuará com diminuição ou aumento da quantidade de biomassa ou de estoque de carbono.

Porém, a utilização da altura implica, no caso de haver erros de medição, que este se propagará para a estimativa da biomassa a nível de área (FORTIN; DEBLOIS, 2010). A altura da árvore não diminuiu consideravelmente os erros das estimativas da biomassa do fuste na pesquisa de Zianis e Mencuccini (2003), com biomassa aérea de árvores de *Fagus moesiaca* Cz., na montanha Vermio, norte da Grécia. Esses autores atribuem a pouca melhora à multicolinearidade existente entre o diâmetro medido a 1,3 m e a altura total.

A utilização da h_t em consonância com o dap_{cc} para estimar a biomassa seca e o carbono orgânico estocado no lenho aumentou a amplitude dos resíduos, todavia, essas equações apresentaram, claramente, resíduos padronizados melhor

distribuídos em torno da reta 0, com distribuição aleatória, indicando, homogeneidade das variâncias (FIGURA 17).

FIGURA 17 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

Resíduos com variâncias não homogênea, como observados nas equações derivadas de modelos que utilizam somente o dap_{cc} como variável preditora, são comuns nas estimativas da biomassa de árvores (WAYSON et al., 2015), e por consequência, tendem a ser comuns, também, na modelagem do estoque de carbono orgânico. Os resultados da TABELA 32 mostram que as redes treinadas para estimar a biomassa seca e o estoque de carbono orgânico no componente lenho, representaram com precisão os dados observados, pois as REQM estão abaixo de 10%.

TABELA 32 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-5-1	79	6,521723	8,38	0,9804	0,9697	0,3524	$y = 0,956143x + 3,235918$
	11-6-1	84	7,340013	9,43	0,9751	0,9726	0,4347	$y = 0,949949x + 3,661784$
	12-6-1	100	4,790357	6,15	0,9896	0,9106	< 0,05	$y = 0,967957x + 2,101859$
	12-4-1	178	4,490487	5,77	0,9908	0,9140	< 0,05	$y = 0,973242x + 1,902049$
Carbono	11-5-1	83	2,869107	8,32	0,9804	0,9704	0,3711	$y = 0,955069x + 1,479577$
	11-6-1	85	3,243893	9,41	0,9749	0,9741	0,4818	$y = 0,949080x + 1,643007$
	12-6-1	100	2,199878	6,38	0,9887	0,9023	< 0,05	$y = 0,966424x + 0,991942$
	12-4-1	168	2,120515	6,15	0,9894	0,9070	< 0,05	$y = 0,969915x + 0,961374$

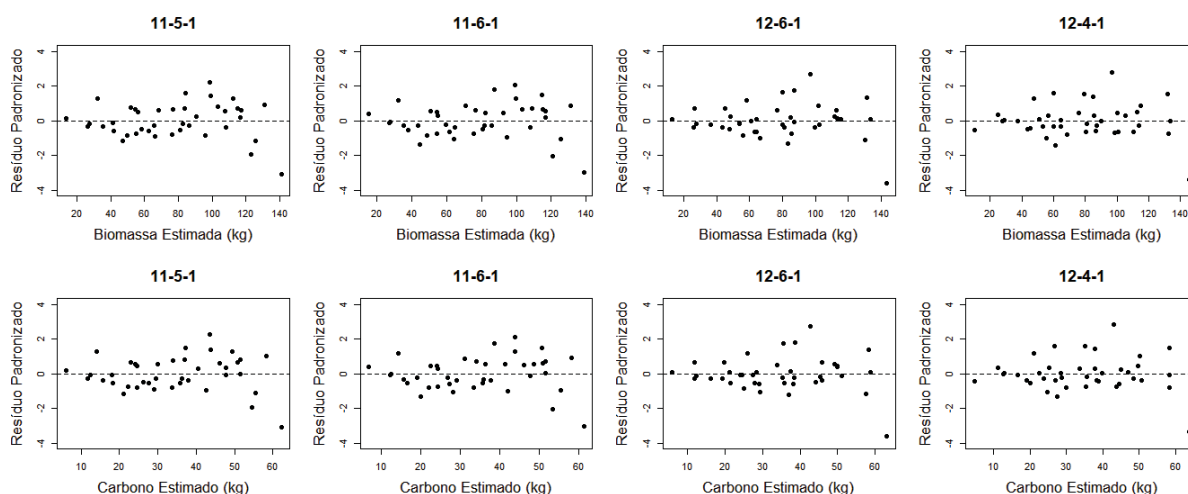
FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As redes treinadas com dap_{cc} , ht e materiais genéticos, na camada de entrada, e quatro neurônios, na camada intermediária, apresentaram-se como melhores preditoras em ambas variáveis, mesmo com menor quantidade de neurônios, por terem apresentado as melhores medidas de precisão, inclusive quando comparadas às estimativas das melhores equações.

As redes neurais artificiais treinadas, apresentaram resíduos padronizados mais próximos de 0, em comparação com os resíduos das equações geradas por regressão não linear, e ao compará-las, percebe-se que as redes que incluíram a altura na camada de entrada, apresentaram resíduos padronizados com maior amplitude (FIGURA 18).

FIGURA 18 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

Verificou-se pela precisão das estimativas para o conjunto de teste, que o modelo Hjelm-Johansson gerou a equação que melhor estimou a biomassa seca e o estoque de carbono orgânico, pois apresentou menor REQ_M e maior r_{yy} , mesmo não tendo apresentado melhores estimativas dessas variáveis nos indivíduos do conjunto de ajuste (TABELA 33).

TABELA 33 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Regressão não linear	Monomolecular incompleto	8,937655	12,22	0,9463	19,3429	0,4350
		Hjelm-Johansson	5,848215	7,99	0,9853	7,7726	0,9888
	Rede neural artificial	11-5-1	8,814132	12,05	0,9664	15,1698	0,7117
		12-6-1	7,075655	9,67	0,9792	10,2519	0,9465
Carbono	Regressão não linear	Monomolecular incompleto	3,933856	12,11	0,9461	8,6470	0,9789
		Hjelm-Johansson	2,619969	8,07	0,9829	3,5285	1,0000
	Rede neural artificial	11-5-1	3,838218	11,82	0,9658	6,4628	0,9966
		12-6-1	3,143456	9,68	0,9770	4,6166	0,9997

FONTE: O autor (2019).

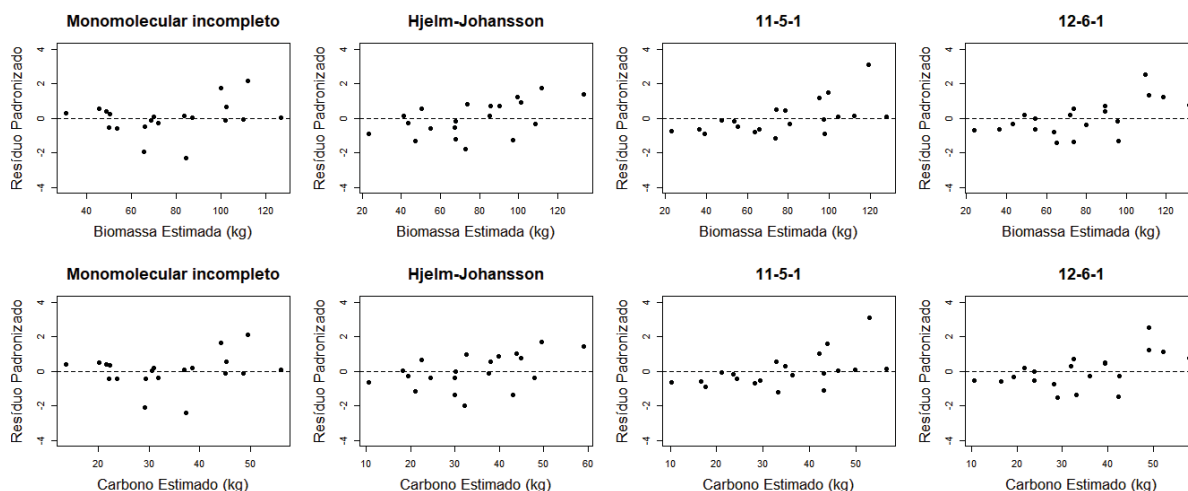
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

Os resultados do teste evidenciaram que há diferença na precisão das equações quando se utiliza um único preditor (dap_{cc}) ou dois preditores (dap_{cc} e h_t). Dong et al. (2016) apresentaram resultados semelhantes ao testarem dois sistemas de equação no desenvolvimento de equações aditivas, estes autores ressaltaram que a adição da variável altura ao sistema de equações de biomassa pode melhorar marginalmente o ajuste para a biomassa do lenho.

No entanto, não se esperava que as equações oriundas das redes neurais apresentariam desempenho inferior; e isso pode indicar que estimativas robustas de biomassa seca e de carbono orgânico estocado no lenho podem ser feitas para diferentes espécies de *Eucalyptus*, usando equações alométricas gerais, sem a necessidade de desenvolver equações específicas para cada espécie.

Os resíduos padronizados das estimativas da biomassa seca e do estoque de carbono orgânico no componente lenho das observações do conjunto de teste, feitas pelas equações oriundas das redes treinadas e do modelo Monomolecular incompleto, explicitaram a menor precisão dessas equações em comparação a precisão do modelo Hjelm-Johansson (FIGURA 19).

FIGURA 19 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Ainda, ao avaliar a homogeneidade da distribuição dos resíduos, percebe-se tendência nas estimativas das RNA, mesmo que estejam balanceadas, sendo bem marcante à subestimação seguida de superestimação, inviabilizando a indicação da equação. Contrapondo esses resultados, Lafetá et al. (2018) chegaram à conclusão de que redes neurais artificiais podem ser utilizadas com boa precisão na modelagem da biomassa seca produzida pelo lenho de árvores de eucalipto, mas considerando diferentes espaçamentos e não diferentes espécies.

3.3.6 Total dos componentes

Assim como no componente lenho, todos os modelos que utilizam somente o dap_{cc} como variável independente, o modelo Spurr e o modelo Hjelms-Johansson apresentaram coeficientes ajustados significativos para estimar a biomassa seca e o estoque de carbono orgânico no total dos componentes (TABELA 34).

TABELA 34 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES

(continua)

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Logístico	β_0	303,9424544	58,339	< 0,05	132,2901704	25,026	< 0,05
	β_1	99,2845927	18,442	< 0,05	98,6308266	18,966	< 0,05
	β_2	0,2565697	0,029	< 0,05	0,2578246	0,030	< 0,05

TABELA 34 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES

(conclusão)

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Monomolecular incompleto	β_0	-12,4938965	1,604	< 0,05	-5,6046997	0,729	< 0,05
	β_1	0,1437164	0,007	< 0,05	0,1429143	0,007	< 0,05
Michaelis-Menten	β_0	-74,4937803	5,265	< 0,05	-33,1551976	2,377	< 0,05
	β_1	-26,8174936	0,698	< 0,05	-26,8847396	0,713	< 0,05
Exponencial	β_0	8,2681246	0,831	< 0,05	3,6932439	0,375	< 0,05
	β_1	0,1624301	0,006	< 0,05	0,1618018	0,006	< 0,05
Spurr	β_0	0,0170491	0,005	< 0,05	0,0078606	0,002	< 0,05
	β_1	1,0127745	0,031	< 0,05	1,0079680	0,032	< 0,05
Schumacher-Hall	β_0	0,0278515	0,015	0,0695	0,0133825	0,007	0,0747
	β_1	2,1582510	0,140	< 0,05	2,1602620	0,143	< 0,05
	β_2	0,7405321	0,257	< 0,05	0,7124130	0,263	< 0,05
Péllico Netto	β_0	-0,4212248	1,411	0,7669	-0,2364992	0,639	0,7132
	β_1	0,0448541	0,194	0,8183	0,0279986	0,088	0,7515
	β_2	0,0179339	0,007	< 0,05	0,0076189	0,003	< 0,05
Hjelm-Johansson	β_0	3,6287215	0,304	< 0,05	2,7098529	0,235	< 0,05
	β_1	-0,2047875	0,024	< 0,05	-0,0943891	0,012	< 0,05
	β_2	0,0222449	0,001	< 0,05	0,0100193	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e pvalue é a significância dos coeficientes estimados.

As medidas que avaliam a qualidade das estimativas permitem observar maior precisão da equação derivada do modelo Péllico Netto para estimar a biomassa seca e o carbono orgânico estocado no total dos componentes (TABELA 35). Independentemente do modelo ajustado para estimar essas variáveis, a REQM não foi superior a 9,3% e o r_{yy} não foi inferior a 0,977, além disso, todos apresentaram resíduos com distribuição normal.

TABELA 35 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(continua)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	pvalue	
Biomassa	Monomolecular incompleto	7,773101	8,19	0,9813	0,9873	0,9266	$y = 0,938928x + 6,192558$
	Michaelis-Menten	8,763824	9,23	0,9773	0,9830	0,7980	$y = 0,904676x + 9,849972$
	Spurr	6,491833	6,84	0,9868	0,9479	0,0645	$y = 0,970807x + 2,820459$
	Péllico Netto	6,470531	6,82	0,9869	0,9468	0,0590	$y = 0,976519x + 2,184641$

TABELA 35 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(conclusão)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Carbono	Logístico	3,236496	7,71	0,9831	0,9794	0,6681	$y = 0,959880x + 1,733303$
	Monomolecular incompleto	3,476657	8,28	0,9808	0,9822	0,7707	$y = 0,937470x + 2,802480$
	Spurr	2,938815	7,00	0,9861	0,9548	0,1111	$y = 0,968823x + 1,335101$
	Péllico Netto	2,928752	6,97	0,9862	0,9552	0,1146	$y = 0,975441x + 1,009467$

FONTE: O autor (2019).

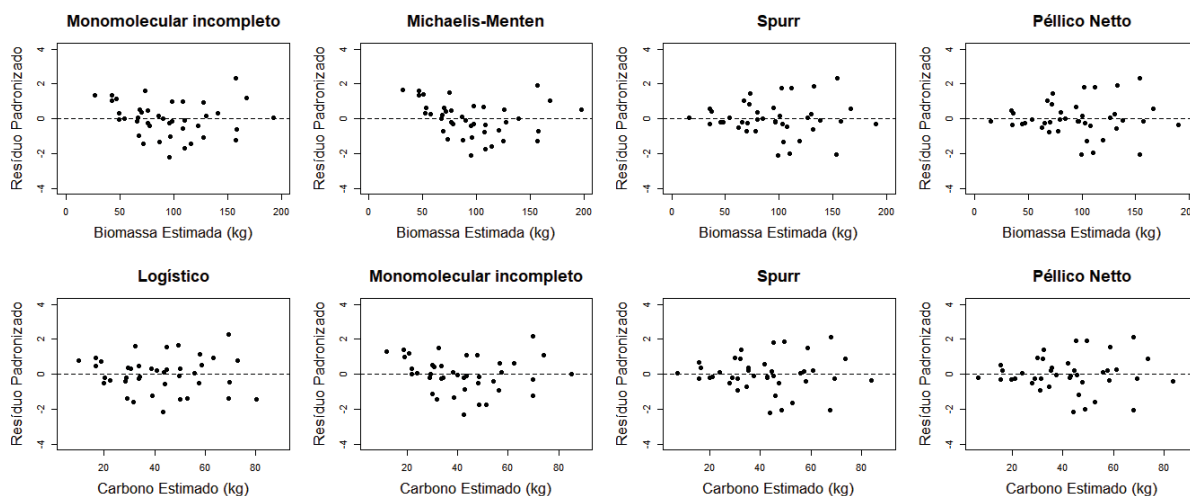
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As equações geradas com os modelos que utilizam a h_t , além do dap_{cc} , para estimar a biomassa seca e o estoque de carbono no total dos componentes melhoraram a precisão das estimativas, em comparação com a precisão dos modelos que utilizam somente o dap_{cc} como variável independente. Isto também foi observado em resultados de outros estudos (SAWADOGO et al., 2010), mas melhoria substancial foi observada principalmente nas equações ajustadas para estimar a biomassa seca.

Esses resultados contribuem com a sugestão feita por Feldpausch et al. (2012), ao ressaltarem que a altura da árvore é um importante fator alométrico e que esta precisa ser considerada para melhorar a estimativa da biomassa florestal, no entanto, contrapõem os resultados encontrados em outros estudos (KRIDIBORWORN et al., 2012; GUEDES et al., 2018).

Devido à dificuldade de medição de altura, equações alométricas sem um parâmetro de altura podem ser muito úteis em inventário florestal, quando estas mostrarem estimativas com precisão semelhante à das equações que também utilizam a altura, como ocorreu com o estoque de carbono orgânico. Contudo, não basta semelhança entre as medidas de precisão, é preciso observar, também, a distribuição residual, e esta comprova que a utilização da h_t e do dap_{cc} como variáveis independentes para estimar ambas variáveis melhorou substancialmente a distribuição dos resíduos padronizados, deixando-os mais homogêneos em torno de zero (FIGURA 20).

FIGURA 20 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

No geral, as redes treinadas para estimar a biomassa seca e o carbono orgânico estocado no total dos componentes apresentaram-se mais precisas, com menores REQM e maiores r_{yy} (TABELA 36).

TABELA 36 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	pvalue	
Biomassa	11-5-1	84	7,356293	7,75	0,9830	0,9647	0,2412	$y = 0,961591x + 3,382017$
	11-4-1	78	8,251712	8,69	0,9785	0,9858	0,8884	$y = 0,957945x + 3,852037$
	12-6-1	110	5,246852	5,53	0,9915	0,9142	< 0,05	$y = 0,972462x + 2,254055$
	12-5-1	131	5,402666	5,69	0,9909	0,9627	0,2064	$y = 0,971253x + 2,390578$
Carbono	11-5-1	84	3,216203	7,66	0,9833	0,9595	0,1616	$y = 0,962257x + 1,475641$
	11-4-1	92	3,302260	7,86	0,9824	0,9754	0,5232	$y = 0,961385x + 1,449537$
	12-3-1	207	2,467351	5,88	0,9903	0,9439	< 0,05	$y = 0,970103x + 1,039471$
	12-6-1	126	2,240338	5,33	0,9920	0,9083	< 0,05	$y = 0,973616x + 0,941341$

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, pvalue é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

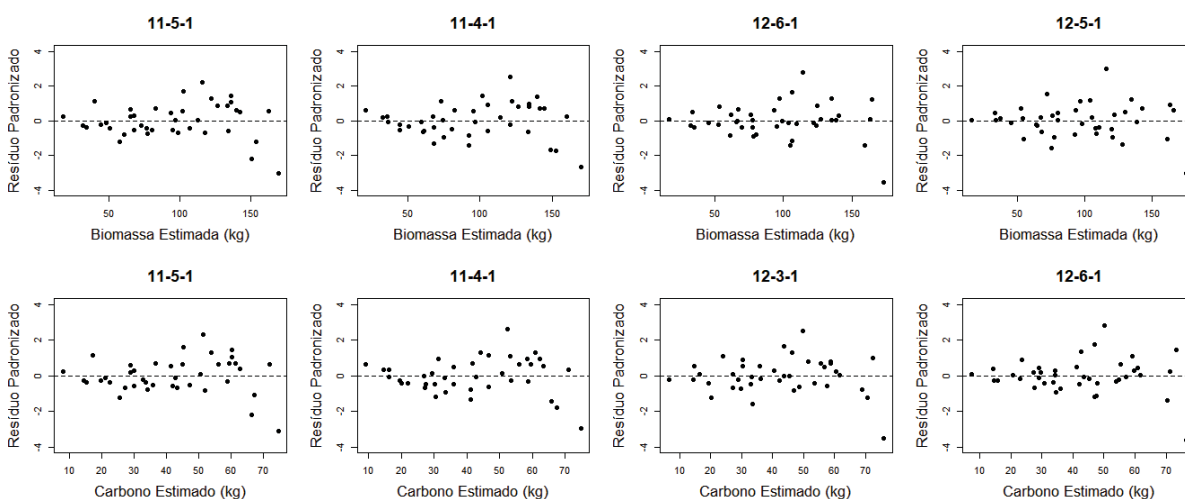
Independentemente da rede treinada para estimar essas variáveis, a REQM não foi superior a 8,7% e o r_{yy} não foi inferior a 0,978, mas a rede treinada que apresentou as melhores medidas de precisão, não apresentou resíduos com distribuição normal. Em comparação com as equações alométricas desenvolvidas por regressão não linear, os valores de REQM e r_{yy} obtidos pelas melhores redes neurais

treinadas, foram melhores nas duas variáveis, além disso, os coeficientes da equação linear, também, foram melhores.

Özçelik et al. (2017) treinaram redes neurais artificiais com o algoritmo de Levenberg-Marquardt (LMANN), para estimativa da biomassa de *Pinus brutia* da região do Mediterrâneo Ocidental da Turquia, e as compararam com regressões não lineares aparentemente não relacionadas (NSUR), visando sugerir o método mais preciso, e chegaram à conclusão de que os erros das estimativas feitas para o total dos componentes, produzidos pela soma das estimativas de cada componente, pela LMANN foi 26,6% menor que os oriundos do modelo NSUR.

Assim como nas estimativas do componente lenho, a utilização da h_t , do dap_{cc} e dos materiais genéticos na camada de entrada para estimar a biomassa seca e o carbono orgânico estocado no total dos componentes, melhorou a distribuição dos resíduos padronizados, deixando-os mais próximos da reta 0, principalmente, nas redes com seis neurônios na camada intermediária, contudo, gerou duas estimativas com maiores erros (FIGURA 21).

FIGURA 21 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

O modelo Spurr gerou estimativas mais precisas da biomassa seca e do carbono orgânico estocado no total dos componentes, para o conjunto de teste, adversamente, a rede que utiliza cinco neurônios na camada intermediária e o dap_{cc} mais os materiais genéticos na camada de entrada; e o modelo Logístico, apresentaram, respectivamente, estimativas menos precisas (TABELA 37).

TABELA 37 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Regressão não linear	Michaelis-Menten	9,256468	10,38	0,9608	20,2025	0,3825
		Spurr	7,480721	8,39	0,9825	10,5691	0,9375
	Rede neural artificial	11-5-1	9,737728	10,92	0,9776	14,8438	0,7325
		12-6-1	8,708149	9,77	0,9814	12,4415	0,8659
Carbono	Regressão não linear	Logístico	4,379568	11,09	0,9657	8,0740	0,9859
		Spurr	3,444426	8,73	0,9789	5,1415	0,9993
	Rede neural artificial	11-4-1	4,246406	10,76	0,9786	6,3986	0,9968
		12-6-1	3,765324	9,54	0,9805	5,2502	0,9992

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

Isto indica que equações alométricas genéricas a nível de local ajustadas somente com o dap_{cc} e com a h_t como variáveis preditoras foram mais precisas para estimativa da biomassa seca e do estoque de carbono em oposição a equações desenvolvidas com RNA que incluíram, também, a espécie como variável preditora. Resultado semelhante foi obtido por Paul et al. (2013), que concluíram que equações alométricas genéricas desenvolvidas para estimativa da biomassa aérea produzida por três espécies de eucaliptos plantadas em um mesmo sítio no sul da Austrália são mais precisas que estimativas de equações desenvolvidas por espécies.


Contrapondo esses resultados, Assis et al. (2015) apresentaram resultados que mostraram que cada material genético apresentou um comportamento particular de produção de biomassa seca e estoque de carbono total, inviabilizando assim a seleção do mesmo modelo para todos os materiais genéticos, indicando que há efeito específico do material genético na produção de biomassa e, consequentemente, de carbono.

A variável combinada ($dap_{cc}^2 h_t$), única utilizada no modelo Spurr como variável preditora, é utilizada em muitos estudos para estimativa da biomassa seca ou do estoque de carbono orgânico em diferentes componentes (SCHMIDT et al., 2009; VARGAS-LARRETA et al., 2017). De fato, a biomassa de árvores está intimamente

correlacionada com $\text{dap}_{\text{cc}}^2 h_t$, como mostrado por Carvalho e Parresol (2003). Ainda, Bi et al. (2004) chegaram a mesma conclusão, ao reportarem que $\text{dap}_{\text{cc}}^2 h_t$ apresentou melhor desempenho para prever a biomassa seca produzida pelo fuste de árvores de eucalipto nativas da Austrália com modelagem aditiva. Entretanto, há pesquisas que relatam que somente a variável dap_{cc} é capaz de estimar com precisão a biomassa seca produzida pelo total dos componentes aéreos (KUSMANA et al., 2018).

Os resíduos padronizados apresentados na FIGURA 22 ratificam a maior precisão do modelo Spurr ao estimar a biomassa seca e o carbono orgânico estocado no total dos componentes, para o conjunto de teste, pois estes estão distribuídos com maior homogeneidade em torno da reta representada pelo valor 0.

FIGURA 22 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Esse resultado corrobora com os resultados encontrados em estudo desenvolvido por Fontoura et al. (2017) com modelagem da biomassa aérea de regeneração natural de *Ateleia glazioviana* Baill. no município de Frederico Westphalen, RS. Mesmo resultado foi evidenciado por Mello e Gonçalves (2008) na estimativa de biomassa seca de árvores de *Eucalyptus grandis*, em que o melhor modelo de regressão linear logaritmizado ajustado obtinha $\text{dap}_{\text{cc}}^2 h_t$ como variável independente. Dessa forma, considerou-se o modelo Spurr como o mais adequado para as estimativas da biomassa seca e do estoque de carbono orgânico no total dos componentes.

3.3.7 Componente copa

Com exceção do coeficiente β_0 do modelo logístico ajustado para estimar a biomassa seca e o estoque de carbono orgânico na copa, todos os outros coeficientes ajustados dos demais modelos que utilizam somente o dap_{cc} como variável independente foram significativos, em contrapartida, a maioria dos coeficientes ajustados dos modelos que utilizam dap_{cc} e h_t foram não significativos, e um destaque positivo cabe ao modelo Hjelm-Johansson, por apresentar todos os coeficientes significativos (TABELA 38).

TABELA 38 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	pvalue	Valor Estimado	Erro padrão	pvalue
Logístico	β_0	53,9237463	61,651	0,3874	23,3531781	24,754	0,3516
	β_1	118,6741003	57,166	< 0,05	115,1560702	48,822	< 0,05
	β_2	0,2211175	0,075	< 0,05	0,2236772	0,075	< 0,05
Monomolecular incompleto	β_0	-1,0823767	0,346	< 0,05	-0,5020905	0,161	< 0,05
	β_1	0,1555711	0,018	< 0,05	0,1546975	0,018	< 0,05
Michaelis-Menten	β_0	-7,2219455	1,072	< 0,05	-3,3205103	0,496	< 0,05
	β_1	-25,8579953	1,302	< 0,05	-25,9188407	1,320	< 0,05
Exponencial	β_0	0,7623335	0,188	< 0,05	0,3521144	0,087	< 0,05
	β_1	0,1716364	0,015	< 0,05	0,1709476	0,015	< 0,05
Spurr	β_0	0,0012798	0,001	0,2838	0,0005991	0,001	0,2802
	β_1	1,0531307	0,105	< 0,05	1,0503291	0,104	< 0,05
Schumacher-Hall	β_0	0,0880511	0,131	0,5057	0,0330972	0,050	0,5098
	β_1	3,2719664	0,431	< 0,05	3,2004230	0,433	< 0,05
	β_2	-1,3143054	0,748	0,0871	-1,1894027	0,753	0,1226
Péllico Netto	β_0	0,2690252	0,496	0,5904	0,1120133	0,225	0,6217
	β_1	-0,0428126	0,068	0,5334	-0,0179354	0,031	0,5655
	β_2	0,0036377	0,002	0,1232	0,0016038	0,001	0,1342
Hjelm-Johansson	β_0	2,2992135	0,217	< 0,05	1,7089378	0,170	< 0,05
	β_1	-0,0458085	0,009	< 0,05	-0,0216647	0,004	< 0,05
	β_2	0,0031880	0,000	< 0,05	0,0015078	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e p_{value} é a significância dos coeficientes estimados.

O coeficiente ajustado positivo de dap_{cc} e o coeficiente ajustado negativo de h_t no modelo Schumacher-Hall, sugerem que a biomassa seca ou o estoque de carbono orgânico aumentarão com o aumento de dap_{cc} , mas que em árvores com o mesmo dap_{cc} , essas variáveis diminuirão com o aumento da altura das árvores. O modelo Schumacher-Hall mostrou-se mais preciso, entre todos os modelos ajustados,

para estimar a biomassa seca e o estoque de carbono orgânico na copa (TABELA 39), por apresentar a menor REQM e o maior r_{yy} .

TABELA 39 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	pvalue	
Biomassa	Logístico	2,125547	21,00	0,8986	0,9521	0,0896	$y = 0,805460x + 1,973462$
	Monomolecular incompleto	2,129190	21,04	0,8983	0,9479	0,0644	$y = 0,798534x + 2,058091$
	Schumacher-Hall	2,046613	20,22	0,9064	0,9672	0,2915	$y = 0,821570x + 1,805616$
	Hjelm-Johansson	2,146164	21,21	0,8965	0,9561	0,1235	$y = 0,800046x + 2,035580$
Carbono	Logístico	0,969755	20,97	0,8984	0,9522	0,0903	$y = 0,804821x + 0,904851$
	Monomolecular incompleto	0,971762	21,02	0,8980	0,9471	0,0604	$y = 0,797177x + 0,947414$
	Schumacher-Hall	0,939786	20,33	0,9049	0,9659	0,2659	$y = 0,818290x + 0,840750$
	Hjelm-Johansson	0,985396	21,31	0,8949	0,9539	0,1037	$y = 0,798102x + 0,938094$

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, pvalue é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

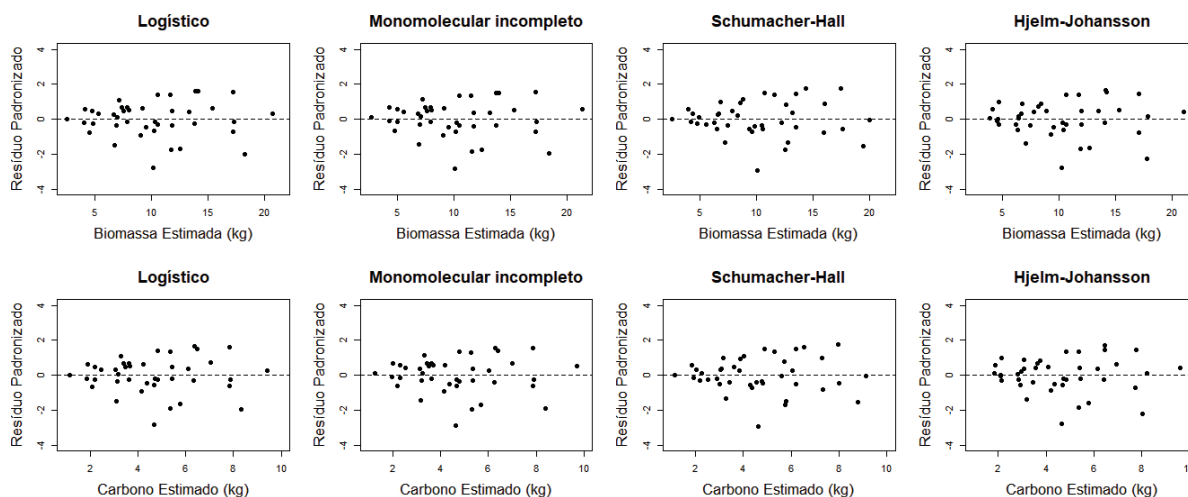
Equação oriunda do modelo Schumacher-Hall também apresentou melhor desempenho para a estimativa da biomassa da copa na pesquisa de Oliveira et al. (2018), contudo, esses autores ajustaram o modelo na forma logarítmica com dados de plantios de *Araucaria angustifolia*, localizados nos municípios de Quedas do Iguaçu e General Carneiro no Sul, Paraná.

No trabalho de Coutinho et al. (2017), as equações ajustadas para estimar a biomassa da copa apresentaram menor precisão em comparação com as precisões dos ajustes para a biomassa do fuste e do total, corroborando com os resultados desta pesquisa. No trabalho desses autores, o modelo de Berkhout que utiliza somente o dap_{cc} como variável preditora, apresentou estimativas da produção de biomassa na copa de árvores da espécie *Cryptomeria japonica*, com 34 anos de idade, mais precisa, contrapondo a necessidade de incluir a h_t como variável preditora.

As distribuições residuais dos modelos ajustados para estimar a biomassa seca e o estoque de carbono no componente copa foram semelhantes (FIGURA 23).

Contudo, o modelo Hjelm-Johansson foi o único que estimou dois valores, em ambas variáveis, com desvios abaixo de -2.

FIGURA 23 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

A rede que utiliza a h_t , o dap_{cc} e os materiais genéticos, na camada de entrada e seis neurônios na camada intermediária, se diferenciou demasiadamente das demais, em precisão (TABELA 40). A REQM dessa rede foi 2,38% inferior àquela da segunda melhor rede treinada e os coeficientes da equação linear foram melhores.

TABELA 40 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-5-1	54	1,659064	16,39	0,9397	0,9815	0,7434	$y = 0,871037x + 1,243289$
	11-6-1	63	1,671171	16,51	0,9388	0,9820	0,7647	$y = 0,874479x + 1,190917$
	12-6-1	103	1,414862	13,98	0,9568	0,9840	0,8312	$y = 0,887636x + 1,139005$
	12-4-1	76	1,688103	16,68	0,9381	0,9468	0,0588	$y = 0,848340x + 1,456363$
Carbono	11-5-1	49	0,762112	16,48	0,9387	0,9839	0,8287	$y = 0,870488x + 0,572430$
	11-6-1	60	0,758547	16,41	0,9393	0,9822	0,7719	$y = 0,876970x + 0,529470$
	12-6-1	102	0,648534	14,03	0,9563	0,9848	0,8586	$y = 0,888752x + 0,513918$
	12-5-1	67	0,781107	16,89	0,9360	0,9721	0,4198	$y = 0,846598x + 0,679784$

FONTE: O autor (2019).

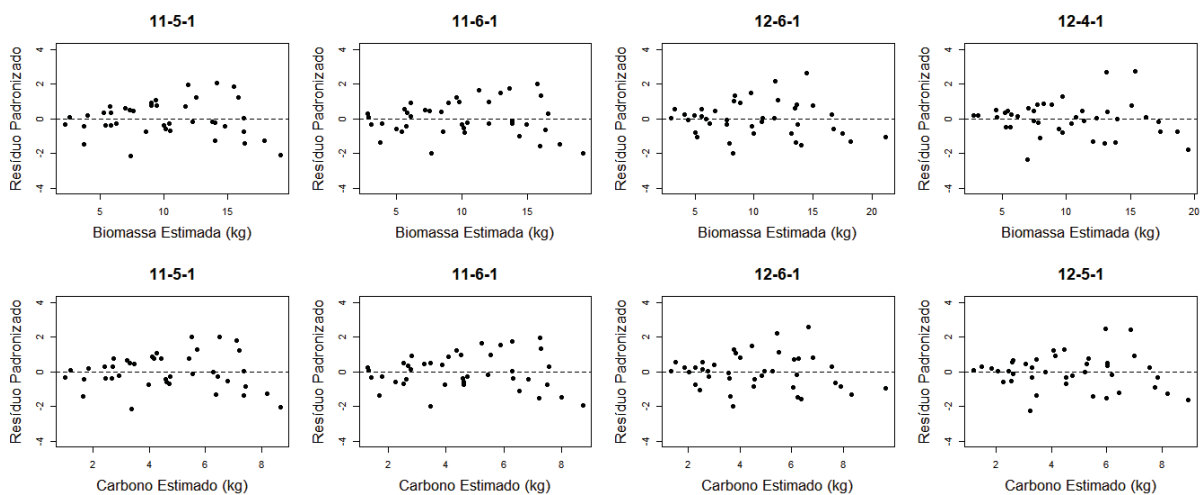
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Pela intensiva busca feita na literatura, supõe-se que esta foi a primeira tentativa ou uma das primeiras tentativas de desenvolver equações a partir de

treinamento de redes neurais artificiais para estimar a biomassa seca ou o estoque de carbono orgânico na copa de árvores, independente da espécie, pois nenhum estudo foi encontrado para comparar os resultados desta pesquisa.

De maneira geral, observou-se diferença nas estimativas entre as equações desenvolvidas por regressão não linear e por rede neural artificial, tendo as redes apresentado melhores resultados que as equações alométricas. As distribuições residuais das redes treinadas para estimar a biomassa seca e o estoque de carbono no componente copa foram semelhantes (FIGURA 24), mas as redes que incluíram o dap_{cc} , a h_t e os materiais genéticos na camada de entrada aproximaram, no geral, os resíduos da reta 0.

FIGURA 24 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

A utilização da h_t na camada de entrada das redes neurais artificiais e como variável independente nos modelos alométricos, para estimar a biomassa seca e o carbono orgânico estocado na copa das árvores, melhorou as estimativas no conjunto de teste, mas as RNA apresentaram-se mais precisa, por apresentarem menor REQM e $r_{\hat{y}y}$ mais próximo de 1 (TABELA 41).

TABELA 41 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	pvalue
Biomassa	Regressão não linear	Logístico	2,174521	22,93	0,8406	8,1140	0,9855
		Schumacher-Hall	1,848019	19,49	0,8948	6,2561	0,9972
	Rede neural artificial	11-5-1	2,026494	21,37	0,8767	7,6869	0,9896
		12-6-1	1,810015	19,09	0,9090	6,1718	0,9975
Carbono	Regressão não linear	Logístico	0,994704	22,93	0,8410	3,7824	0,9999
		Schumacher-Hall	0,865011	19,94	0,8882	3,0185	1,0000
	Rede neural artificial	11-5-1	0,919467	21,20	0,8786	3,4351	1,0000
		12-6-1	0,833076	19,20	0,9070	2,8548	1,0000

FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

González-García et al. (2013) ajustaram dois modelos de potência para estimativa da biomassa seca produzida pela copa de árvores de *Eucalyptus nitens* implantadas no noroeste da Espanha e chegaram ao resultado de que a variável dap_{cc} foi a principal preditora, no entanto, nessa pesquisa foi mostrado que a combinação do dap_{cc} com a h_t melhorou a precisão das equações, e nessa pesquisa a precisão obtida com base na REQM é inferior a deste estudo.

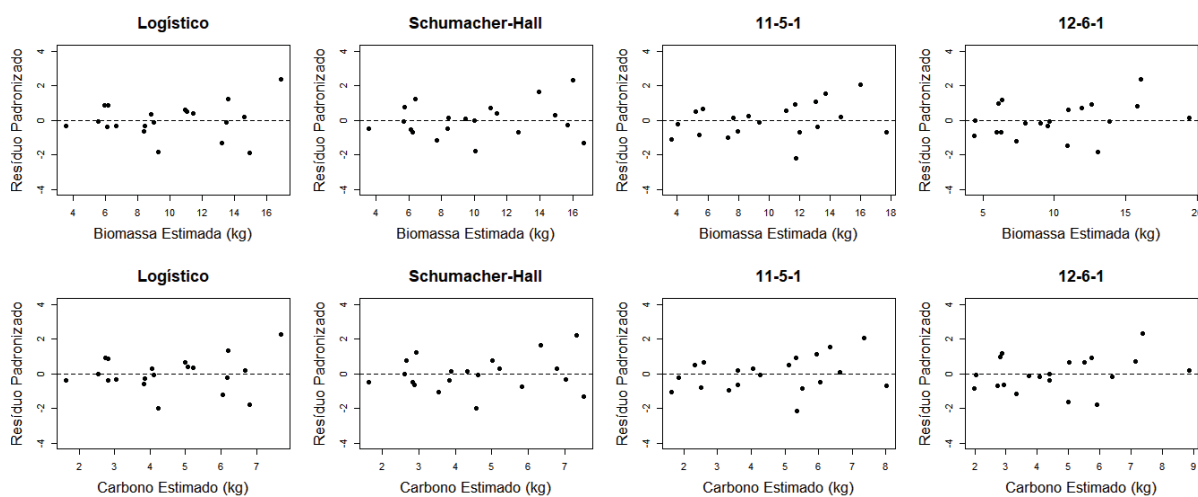
Diversas equações de biomassa seca ou de carbono orgânico específicas para espécies ou para sítios específicos com composição mista de espécies foram publicadas, e as principais relações são com o dap_{cc} e/ou com a h_t . Como os treinamentos das redes foram realizados com a inclusão dos materiais genéticos na camada de entrada, a equação final gerada estimou essas variáveis para um material genético específico e indicou que a variância existente entre os materiais genéticos influencia na precisão.

Sawadogo et al. (2010) relataram que uma equação construída para uma dada espécie é de amplo uso, pois baseado nos resultados de Aboal et al. (2005) não há diferença na produção de biomassa dentro das espécies ao comparar o tipo de floresta, desde que os indivíduos sejam comparados dentro de uma mesma amplitude de dap_{cc} e h_t . Além disso, Arevalo et al. (2007) indicaram que as diferenças nos fatores

biofísicos do sítio podem ser omitidas, pois possuem pouca influência na precisão de equações alométricas.

Não houve grandes diferenças entre as distribuições residuais das equações desenvolvidas por regressão não linear ou por RNA selecionadas para estimar a biomassa seca e o carbono orgânico estocado na copa das árvores separadas para teste, estas apresentaram-se homogêneas e balanceadas em toda amplitude das estimativas (FIGURA 25).

FIGURA 25 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Os resultados mostraram que as equações geradas pela RNA com arquitetura 12-6-1 estimaram com maior precisão, em comparação com as estimativas das equações desenvolvidas por regressão não linear, em ambas variáveis. A adoção ou não de métodos mais precisos, mesmo que apresentem um ganho pequeno em precisão, impactarão em diferenças consideráveis na produção de biomassa ou no estoque de carbono orgânico em locais com grande extensão de florestas plantadas, por exemplo.

3.3.8 Componente tronco

Os modelos Schumacher-Hall e Péllico Netto foram os únicos que apresentaram pelo menos um coeficiente ajustado não significativo para estimativa da biomassa seca e do carbono orgânico estocado no tronco (TABELA 42).

TABELA 42 – COEFICIENTES AJUSTADOS COM REGRESSÃO NÃO LINEAR DOS MELHORES MODELOS DE BIOMASSA SECA E DE CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO

Modelo	Coeficiente	Biomassa			Carbono		
		Valor Estimado	Erro padrão	p _{value}	Valor Estimado	Erro padrão	p _{value}
Logístico	β_0	259,9532213	47,703	< 0,05	112,8104814	20,341	< 0,05
	β_1	99,5771901	20,515	< 0,05	98,9373697	20,944	< 0,05
	β_2	0,2613793	0,030	< 0,05	0,2625848	0,031	< 0,05
Monomolecular incompleto	β_0	-11,4417778	1,530	< 0,05	-5,1167296	0,691	< 0,05
	β_1	0,1423151	0,007	< 0,05	0,1414681	0,007	< 0,05
Michaelis-Menten	β_0	-67,3537233	4,968	< 0,05	-29,8723520	2,230	< 0,05
	β_1	-26,9456355	0,739	< 0,05	-27,0185275	0,754	< 0,05
Exponencial	β_0	7,5120910	0,782	< 0,05	3,3440749	0,350	< 0,05
	β_1	0,1613596	0,006	< 0,05	0,1606977	0,006	< 0,05
Spurr	β_0	0,0158561	0,004	< 0,05	0,0073077	0,002	< 0,05
	β_1	1,0081484	0,030	< 0,05	1,0029311	0,030	< 0,05
Schumacher-Hall	β_0	0,0166516	0,009	0,0599	0,0081486	0,004	0,0655
	β_1	2,0295125	0,133	< 0,05	2,0353902	0,136	< 0,05
	β_2	0,9810134	0,247	< 0,05	0,9424461	0,253	< 0,05
Péllico Netto	β_0	-0,6902499	1,185	0,5637	-0,3485123	0,535	0,5186
	β_1	0,0876666	0,163	0,5934	0,0459340	0,073	0,5358
	β_2	0,0142963	0,006	< 0,05	0,0060151	0,002	< 0,05
Hjelm-Johansson	β_0	3,2155643	0,319	< 0,05	2,4036109	0,246	< 0,05
	β_1	-0,1659968	0,021	< 0,05	-0,0759390	0,010	< 0,05
	β_2	0,0194305	0,001	< 0,05	0,0086853	0,000	< 0,05

FONTE: O autor (2019).

LEGENDA: β_0 , β_1 e β_2 são os coeficientes estimados das equações, e p_{value} é a significância dos coeficientes estimados.

Na TABELA 43, é notável o ganho de precisão dos modelos que utilizam dap_{cc} e a h_t como variáveis independentes para estimar a biomassa seca e o carbono orgânico estocado no tronco, em comparação com os que utilizam somente o dap_{cc} . A diferença da REQM entre o melhor modelo que utiliza o dap_{cc} e a h_t e o melhor modelo que utiliza somente o dap_{cc} foi de, pelo menos, 1,95%, além disso, os coeficientes da equação linear foram melhores.

TABELA 43 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(continua)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Monomolecular incompleto	7,201779	8,49	0,9798	0,9739	0,4738	$y = 0,934265x + 5,949470$
	Michaelis-Menten	8,073000	9,52	0,9757	0,9588	0,1521	$y = 0,899988x + 9,213689$
	Spurr	5,461588	6,44	0,9882	0,9714	0,3969	$y = 0,971600x + 2,482848$
	Hjelm-Johansson	5,773552	6,81	0,9868	0,9698	0,3537	$y = 0,971612x + 2,442769$

TABELA 43 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

(conclusão)

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Carbono	Monomolecular incompleto	3,195227	8,55	0,9794	0,9678	0,3065	$y = 0,933035x + 2,668860$
	Michaelis-Menten	3,573586	9,56	0,9753	0,9691	0,3377	$y = 0,899002x + 4,095499$
	Spurr	2,467746	6,60	0,9875	0,9838	0,8274	$y = 0,969613x + 1,172084$
	Hjelm-Johansson	2,634127	7,05	0,9858	0,9763	0,5539	$y = 0,969511x + 1,155170$

FONTE: O autor (2019).

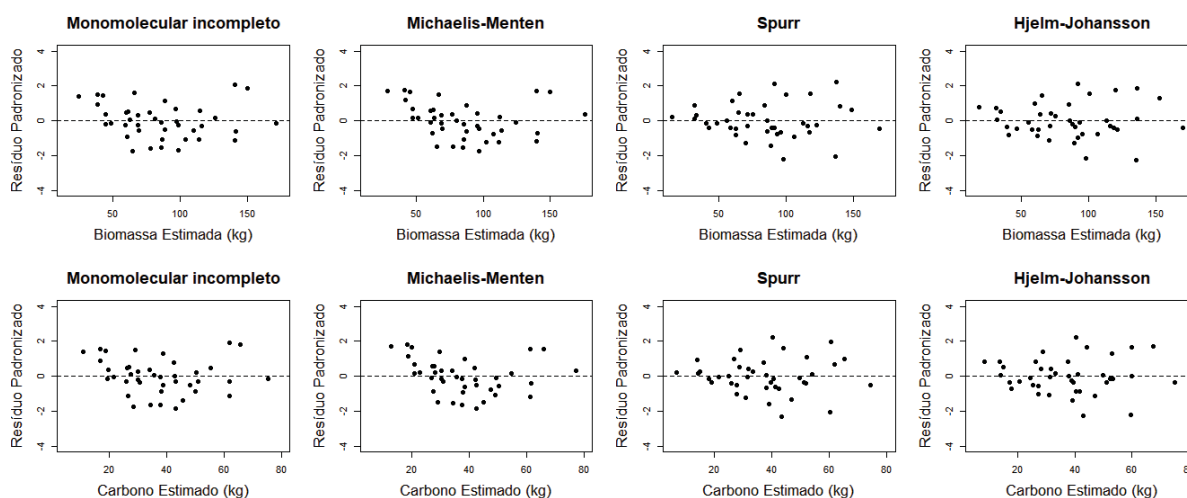
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

Alta precisão foi observada na predição de biomassa seca produzida pelo tronco de árvores presentes em três sítios ao longo da bacia do rio Yala, no oeste do Quênia por Kuyah et al. (2012), ao utilizarem o dap_{cc} como variável independente em uma função alométrica de potência. Isto indica, de acordo com esses pesquisadores, que o dap_{cc} foi um forte indicador de biomassa do tronco, mesmo não sendo algo surpreendentemente novo.

De fato, as equações oriundas de modelos que utilizam somente esta variável, puderam ser consideradas bem ajustadas neste trabalho, por apresentarem REQM inferior a 10%, no entanto, as equações que incluem também a h_t melhoraram substancialmente as estimativas, corroborando com resultados de outros trabalhos publicados anteriormente (COLE; EWEL, 2006; BASTIEN-HENRI et al., 2010).

Os modelos que utilizam somente o dap_{cc} como variável independente para estimar a biomassa seca e o carbono orgânico estocado no tronco das árvores amostradas apresentaram-se altamente enviesados à superestimação nos indivíduos que produziram as menores quantidade dessas variáveis, e a inclusão da h_t tornou a distribuição residual menos enviesada e mais homogênea (FIGURA 26).

FIGURA 26 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR



FONTE: O autor (2019).

Na TABELA 44, é notável que as redes treinadas com dap_{cc} , h_t e materiais genéticos na camada de entrada para estimar a biomassa seca e o carbono orgânico estocado no tronco foram mais precisas, porém, não apresentaram resíduos com distribuição normal.

TABELA 44 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-5-1	72	7,358902	8,68	0,9785	0,9747	0,5001	$y = 0,954595x + 3,481648$
	11-4-1	78	7,658723	9,03	0,9767	0,9893	0,9651	$y = 0,953634x + 3,806562$
	12-6-1	110	4,704732	5,55	0,9914	0,9226	< 0,05	$y = 0,972404x + 2,012651$
	12-4-1	180	4,475158	5,28	0,9921	0,9206	< 0,05	$y = 0,977617x + 1,758400$
Carbono	11-5-1	83	3,031893	8,11	0,9811	0,9742	0,4845	$y = 0,957934x + 1,499306$
	11-4-1	77	3,328989	8,91	0,9771	0,9901	0,9757	$y = 0,954803x + 1,636703$
	12-6-1	97	2,264588	6,06	0,9896	0,9140	< 0,05	$y = 0,966887x + 1,085849$
	12-4-1	181	2,056038	5,50	0,9914	0,9153	< 0,05	$y = 0,975934x + 0,826945$

FONTE: O autor (2019).

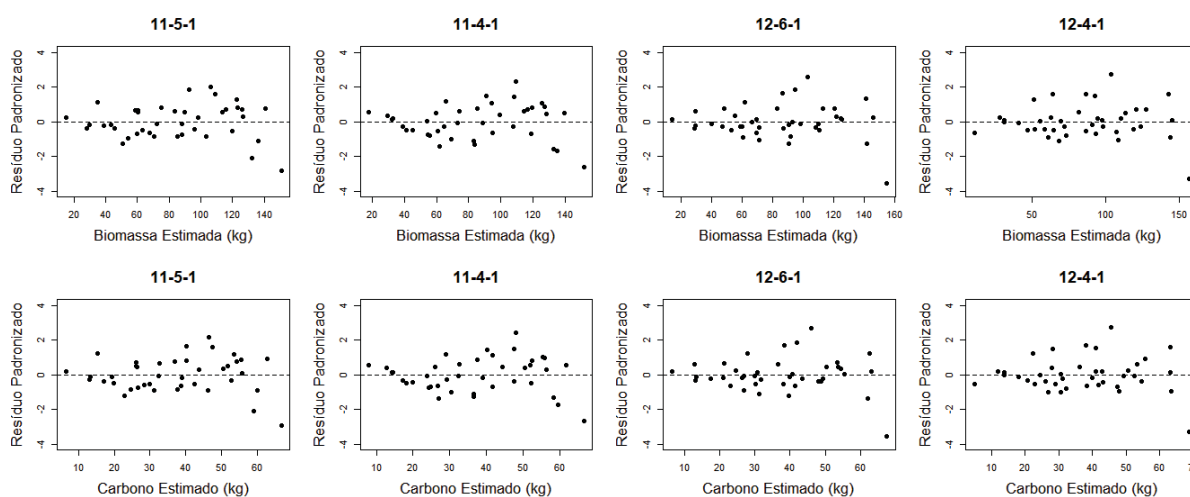
LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg.

As estimativas da biomassa seca e do estoque de carbono orgânico feitas pelas redes neurais artificiais para o conjunto de treinamento foram melhores que as estimativas feitas pelas equações da regressão não linear, pois reduziram os valores da REQM em 18,06% e 16,68%, respectivamente, além disso, também apresentaram melhorias nos valores de r_{yy} e dos coeficientes da equação linear.

Muitas abordagens de modelagem foram testadas para estimativa da biomassa por Sharifi et al. (2016), e as redes neurais artificiais, também, apresentaram estimativas mais precisas em comparação com a precisão dos outros métodos, pois apresentaram maior r_{yy}^2 e menor REQM.

Apesar de todas as redes apresentarem distribuição balanceada, as que utilizam somente o dap_{cc} e os materiais genéticos na camada de entrada para estimar a biomassa seca e o carbono orgânico estocado no tronco das árvores apresentaram resíduos menos compactos, em comparação aos resíduos das redes que incluem a h_t (FIGURA 27), entretanto, essa inclusão estimou o maior valor observado com muito erro.

FIGURA 27 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TREINAMENTO COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR RNA



FONTE: O autor (2019).

As equações oriundas do modelo Hjelm-Johansson realizaram estimativas mais precisas aos indivíduos do conjunto de teste, da biomassa seca e do carbono orgânico estocado no tronco, superando, inclusive, as precisões das estimativas das melhores redes neurais artificiais treinadas (TABELA 45).

TABELA 45 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		χ^2	pvalue
Biomassa	Regressão não linear	Monomolecular incompleto	9,192519	11,54	0,9528	18,8141	0,4688
		Hjelm-Johansson	6,439741	8,08	0,9855	8,2547	0,9839
	Rede neural artificial	11-5-1	9,519080	11,95	0,9668	16,4014	0,6303
		12-6-1	7,644181	9,60	0,9805	10,8192	0,9298
Carbono	Regressão não linear	Monomolecular incompleto	4,083124	11,62	0,9513	8,6775	0,9785
		Hjelm-Johansson	2,946909	8,39	0,9819	3,9724	0,9999
	Rede neural artificial	11-5-1	4,119054	11,72	0,9682	6,8818	0,9948
		12-6-1	3,424265	9,75	0,9779	5,0243	0,9994

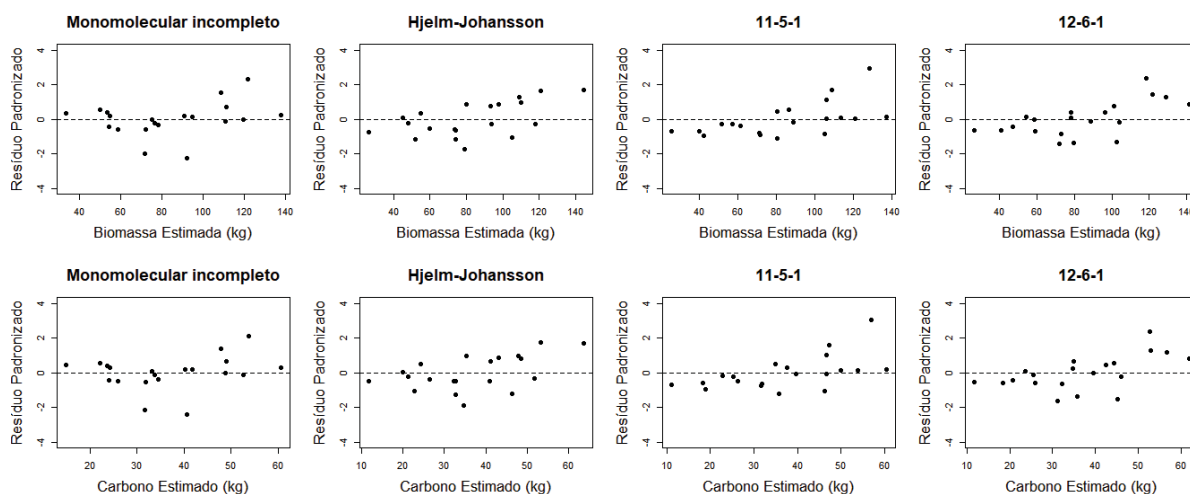
FONTE: O autor (2019).

LEGENDA: REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, χ^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado.

Uma forte relação entre o dap_{cc} e a biomassa seca do tronco foi encontrada por Nelson et al. (2014), ao ajustarem um conjunto aditivo de equações que utilizam somente essa variável como preditora, para cinco espécies de folhosas regeneradas naturalmente no leste de Maine, EUA. Garcia et al. (2011) ajustaram cinco modelos que utilizam o dap_{cc} e a h_t como variáveis preditoras para estimar o carbono estocado no tronco de árvores da Reserva Nacional de Malleco, Chile, e todos apresentaram r_{yy} semelhantes aos obtidos neste trabalho, mas indicaram que a equação desenvolvida com base no modelo Schumacher-Hall foi a mais precisa.

A FIGURA 28 mostra que as estimativas do modelo Hjelm-Johansson apresentaram distribuição dos resíduos mais homogênea em toda amplitude dos dados, ratificando a maior precisão das equações oriundas desse modelo, ao estimar, para o conjunto de teste, a biomassa seca e o carbono orgânico estocado no tronco.

FIGURA 28 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS MELHORES EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

Sempre houve uma grande preocupação para determinação da melhor relação entre a produção de biomassa ou o estoque de carbono orgânico e as variáveis dendrométrica de fácil mensuração, por relação matemática que representem a realidade biológica (SILESHI, 2014), principalmente dos componentes que compõem a copa, devido à baixa relação que existe com o dap_{cc} e com a h_t .

Os resultados obtidos nesta pesquisa mostram que isto pode ser resolvido pela eficiência das RNA na estimativa para esses componentes, pois as relações entre as variáveis preditoras selecionadas e a variável resposta foram bem compreendidas pela RNA, além disso, por não haver restrições para selecionar as variáveis preditoras, a precisão da estimativa pode aumentar por meio da seleção do algoritmo de aprendizado, do tipo de rede e da arquitetura, independentemente da teoria levantada para aplicação de diferentes métodos de regressão, pois a RNA especifica automaticamente a relação funcional que existe entre essas variáveis (VAHEDI, 2017).

Vahedi (2016) salientou que devido à alta eficiência da técnica de RNA no processamento de dados, todos os fatores ambientais e biológicos que influenciam na quantidade e na distribuição de biomassa em diferentes componentes de uma árvore em ecossistemas florestais naturais, podem ser adicionados na camada de entrada como variável preditora para aumentar a precisão e certeza das equações, contrapondo os métodos tradicionais de regressão. Ainda, de acordo com esse autor, a forma de função não linear, o número de variáveis preditoras e a colinearidade entre

elas são as principais preocupações associadas à estimativa nos métodos tradicionais.

Özçelik et al. (2010) apontam que a conveniência e a economia desempenham o papel mais importante na escolha do método a ser usado para estimativas e Özçelik et al. (2014) defendem que a RNA é a melhor opção devido à capacidade de desenvolverem equações não lineares complexas quando a complexidade do problema não pode ser totalmente examinada, ou quando a precisão da estimativa é a parte mais importante em uma pesquisa.

Muitos pesquisadores defendem que a saída das RNA é uma “caixa-preta”, por ser um método que se baseia em computação e por não estar disseminado como são determinados os pesos e *bias* dos neurônios de processamento e as equações geradas após o treinamento, também, existe claramente um conflito entre a seleção de um modelo que é bastante simples de entender e fácil de aplicar (modelo de regressão) e um modelo que, geralmente, é mais preciso, porém mais difícil de compreender (modelo RNA). As equações desenvolvidas pelas RNA que se apresentaram mais precisas para cada componente avaliado estão apresentadas no APÊNDICE 8, assim como as equações geradas pela regressão não linear.

4 CONCLUSÕES

Os materiais genéticos mais adaptados às condições biofísicas do sítio para produção de biomassa e estoque de carbono (C-408, C-455 e C-479) foram de três diferentes espécies (*E. urophylla*, Híbrido de polinização aberta e *E. urophylla* x *E. grandis*), respectivamente.

Individualmente, o material genético C-455 apresentou maiores quantidades média de biomassa seca e de estoque de carbono nos componentes galhos secos, galhos vivos, folhas e lenho; seguido pelos materiais genéticos C-408 (galhos vivos e lenho), C-435 (galhos vivos e casca), C-479 (galhos secos e lenho) e C-500 (galhos vivos).

As primeiras equações alométricas para estimativas da biomassa seca e do carbono orgânico estocado em diferentes componentes acima do solo e no total de árvores implantadas no município de Dom Eliseu, Pará, Brasil, foram desenvolvidas nesse estudo. Essas equações devem ser aplicadas em árvores das mesmas espécies que estejam dentro da faixa das características estruturais medidas, podendo não gerar estimativas tão precisas se aplicadas em áreas onde as condições de crescimento sejam diferentes.

As equações desenvolvidas com rede neural artificial possibilitaram estimativas mais precisas apenas da biomassa seca e do carbono orgânico estocado nos componentes folhas, galhos vivos e copa. Isso pode ser atribuído aos hiperparâmetros utilizados no treinamento; testar outras funções de ativação e/ou outras quantidades de neurônios na camada intermediária poderá tornar as estimativas das redes neurais artificiais mais precisas.

Em contrapartida, equações geradas por regressão não linear forneceram estimativas mais precisas da biomassa seca e do carbono orgânico estocado nos demais componentes (galhos secos, casca, lenho, total e tronco), mesmo não utilizando os diferentes materiais genéticos como variável preditora.

Equações geradas somente com o dap_{cc} como variável preditora apresentaram-se mais precisas ao estimar a biomassa seca e o carbono orgânico estocado nos componentes folhas e casca. Já equações que incluem a h_t , estimaram com maior precisão essas variáveis nos componentes galhos secos, galhos vivos, lenho, total, copa e tronco.

REFERÊNCIAS

- ABOAL, J. R.; ARÉVALO, J. R.; FERNÁNDEZ, Á. Allometric relationships of different tree species and stand above ground biomass in the Gomera laurel forest (Canary Islands). **Flora - Morphology, Distribution, Functional Ecology of Plants**, v. 200, n. 3, p. 264–274, 2005. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0367253005000332>>.
- AJIT; DAS, D. K.; CHATURVEDI, O. P.; JABEEN, N.; DHYANI, S. K. Predictive models for dry weight estimation of above and below ground biomass components of *Populus deltoides* in India: Development and comparative diagnosis. **Biomass and Bioenergy**, v. 35, n. 3, p. 1145–1152, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.biombioe.2010.12.001>>.
- ANTÓNIO, N.; TOMÉ, M.; TOMÉ, J.; SOARES, P.; FONTES, L. Effect of tree, stand, and site variables on the allometry of *Eucalyptus globulus* tree biomass. **Canadian Journal of Forest Research**, v. 37, n. 5, p. 895–906, 2007. Disponível em: <<http://www.nrcresearchpress.com/doi/abs/10.1139/X06-276>>.
- AREVALO, C. B. M.; VOLK, T. A.; BEVILACQUA, E.; ABRAHAMSON, L. Development and validation of aboveground biomass estimations for four *Salix* clones in central New York. **Biomass and Bioenergy**, v. 31, n. 1, p. 1–12, 2007. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0961953406001140>>.
- ASSIS, M. R.; TRUGILHO, P. F.; ROSADO, S. C. DA S.; PROTASIO, T. DE P.; GOULART, S. L. Modelagem da biomassa e do estoque de carbono em plantas jovens de *Eucalyptus*. **Scientia Forestalis/Forest Sciences**, v. 43, n. 105, p. 225–233, 2015. Disponível em: <<http://www.ipef.br/publicacoes/scientia/leitura.asp?Article=23&Number=105&p=s>>.
- BANDARA, W.; ATHTHANAYAKE, A. Generic assumption vs. empirical model in stem carbon prediction of *Eucalyptus grandis* Wall ex. Maiden. **Journal of the National Science Foundation of Sri Lanka**, v. 46, n. 3, p. 411–422, 2018. Disponível em: <<https://jnsfsl.sljol.info/article/10.4038/jnsfsr.v46i3.8493/>>.
- BARTLETT, M. S. Properties of Sufficiency and Statistical Tests. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 160, n. 901, p. 268–282, 1937. Disponível em: <<http://rspa.royalsocietypublishing.org/cgi/doi/10.1098/rspa.1937.0109>>.
- BASTIEN-HENRI, S.; PARK, A.; ASHTON, M.; MESSIER, C. Biomass distribution among tropical tree species grown under differing regional climates. **Forest Ecology and Management**, v. 260, n. 3, p. 403–410, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.foreco.2010.04.035>>.
- BEHLING, A.; SANQUETTA, C. R.; CORTE, A. P. D.; SIMON, A. A.; NUNES, G. S. Equações simultâneas para estimativa da biomassa em plantios comerciais de acácia negra. **Enciclopédia Biosfera**, v. 8, n. 15, p. 853–860, 2012. Disponível em:

<http://www.conhecer.org.br/enciclop/2012b/ciencias_agrarias/equacoes_simultaneas.pdf>.

BERNARDO, A. L.; REIS, M. G. F.; REIS, G. R.; HARRISON, R. B.; FIRME, D. J. Effect of spacing on growth and biomass distribution in *Eucalyptus camaldulensis*, *E. pellita* and *E. urophylla* plantations in southeastern Brazil. **Forest Ecology and Management**, v. 104, n. 1-3, p. 1–13, 1998. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378112797001990>>.

BI, H.; TURNER, J.; LAMBERT, M. Additive biomass equations for native eucalypt forest trees of temperate Australia. **Trees**, v. 18, n. 4, p. 467–479, 2004. Disponível em: <<http://link.springer.com/10.1007/s00468-004-0333-z>>.

BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Statistical Society**, v. 26, n. 2, p. 211–252, 1964. Disponível em: <<https://www.jstor.org/stable/2984418>>.

BRAHMA, B.; NATH, A. J.; SILESHI, G. W.; DAS, A. K. Estimating biomass stocks and potential loss of biomass carbon through clear-felling of rubber plantations. **Biomass and Bioenergy**, v. 115, n. April, p. 88–96, 2018. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0961953418301089>>.

BRAHMA, B.; SILESHI, G. W.; NATH, A. J.; DAS, A. K. Development and evaluation of robust tree biomass equations for rubber tree (*Hevea brasiliensis*) plantations in India. **Forest Ecosystems**, v. 4, n. 14, 2017. Disponível em: <<http://forestecosyst.springeropen.com/articles/10.1186/s40663-017-0101-3>>.

BÚRQUEZ, A.; MARTÍNEZ-YRÍZAR, A. Accuracy and bias on the estimation of aboveground biomass in the woody vegetation of the Sonoran Desert. **Botany**, v. 89, n. 9, p. 625–633, 2011. Disponível em: <<http://www.nrcresearchpress.com/doi/abs/10.1139/b11-050>>.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas**. Viçosa: Editora UFV, 2006.

CANNELL, M. G. R.; DEWAR, R. C. Carbon allocation in trees: a review of concepts for modelling. **Advances in Ecological Research**, v. 25, p. 59–104, 1994. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0065250408602135>>.

CARVALHO, J. P.; PARRESOL, B. R. Additivity in tree biomass components of Pyrenean oak (*Quercus pyrenaica* Willd.). **Forest Ecology and Management**, v. 179, n. 1–3, p. 269–276, 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112702005492>>.

CHABI, A.; LAUTENBACH, S.; OREKAN, V. O. A.; KYEI-BAFFOUR, N. Allometric models and aboveground biomass stocks of a West African Sudan Savannah watershed in Benin. **Carbon Balance and Management**, v. 11, n. 1, p. 16, 2016. Disponível em: <<https://cbmjournal.biomedcentral.com/articles/10.1186/s13021-016-0058-5>>.

CHEN, H.; ENGVIST, O.; WANG, Y.; OLIVECRONA, M.; BLASCHKE, T. The rise of deep learning in drug discovery. **Drug Discovery Today**, v. 23, n. 6, p. 1241–1250, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1359644617303598>>.

CHU, S. Carbon capture and sequestration. **Science**, v. 325, n. 5948, p. 1599–1599, 2009. Disponível em: <<http://www.sciencemag.org/cgi/doi/10.1126/science.1181637>>.

COCHRAN, W. G. **Sampling techniques**. Rio de Janeiro: Fundo de Cultura, 1965.

COLE, T. G.; EWEL, J. J. Allometric equations for four valuable tropical tree species. **Forest Ecology and Management**, v. 229, n. 1–3, p. 351–360, 2006. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112706002635>>.

CORNET, D.; SIERRA, J.; TOURNEBIZE, R. Assessing allometric models to predict vegetative growth of yams in different environments. **Agronomy Journal**, v. 107, n. 1, p. 241, 2015. Disponível em: <<https://dl.sciencesocieties.org/publications/aj/abstracts/107/1/241>>.

COUTINHO, V. M.; SANQUETTA, C. R.; SANQUETTA, M. N. I.; RODRIGUES, A. L.; CORTE, A. P. D. Equações tradicionais e simultâneas para biomassa de compartimentos aéreos de *Cryptomeria japonica* (L.F.) D. Don. **Revista Brasileira de Biometria**, v. 35, n. 1, p. 58–75, 2017. Disponível em: <<http://www.biometria.ufla.br/index.php/BBJ/article/view/295>>.

DEB, D.; SINGH, J. P.; DEB, S.; et al. An alternative approach for estimating above ground biomass using Resourcesat-2 satellite data and artificial neural network in Bundelkhand region of India. **Environmental Monitoring and Assessment**, v. 189, n. 11, p. 576, 2017. Disponível em: <<http://link.springer.com/10.1007/s10661-017-6307-6>>.

DIÉDHIOU, I.; DIALLO, D.; MBENGUE, A. A.; et al. Allometric equations and carbon stocks in tree biomass of *Jatropha curcas* L. in Senegal's Peanut Basin. **Global Ecology and Conservation**, v. 9, p. 61–69, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2351989416301081?via%3Dihub>>.

DONG, L.; ZHANG, L.; LI, F. Developing two additive biomass equations for three coniferous plantation species in Northeast China. **Forests**, v. 7, n. 12, p. 136, 2016. Disponível em: <<http://www.mdpi.com/1999-4907/7/7/136>>.

DOWNES, G. M.; HUDSON, I. L.; RAYMOND, C. A.; et al. **Sampling plantation eucalypts for wood and fibre properties**. Melbourne: CSIRO, 1997.

DROOGENBROECK, B. V.; BREYNE, P.; GOETGHEBEUR, P.; et al. AFLP analysis of genetic relationships among papaya and its wild relatives (Caricaceae) from Ecuador. **Theoretical and Applied Genetics**, v. 105, n. 2–3, p. 289–297, 2002. Disponível em: <<http://link.springer.com/10.1007/s00122-002-0983-4>>.

ELOY, E.; SILVA, D. A. da; CARON, B. O.; ELLI, E. F.; SCHWERZ, F. Effect of age and spacing on biomass production in forest plantations. **Revista Árvore**, v. 42, n. 2, 2018. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622018000200213&lng=en&tlng=en>.

FELDPAUSCH, T. R.; LLOYD, J.; LEWIS, S. L.; et al. Tree height integrated into pantropical forest biomass estimates. **Biogeosciences**, v. 9, n. 8, p. 3381–3403, 2012. Disponível em: <<https://www.biogeosciences.net/9/3381/2012/>>.

FONTOURA, M. R.; CARON, B. O.; ELOY, E.; et al. Modelos alométricos para estimativa de biomassa em área de regeneração natural de *Ateleia glazioviana* Baill. **Floresta**, v. 47, n. 4, p. 469–478, 2017. Disponível em: <<https://revistas.ufpr.br/floresta/article/view/53988>>.

FORTIN, M.; DEBLOIS, J. A statistical estimator to propagate height prediction errors into a general volume model. **Canadian Journal of Forest Research**, v. 40, n. 10, p. 1930–1939, 2010. Disponível em: <<http://www.nrcresearchpress.com/doi/10.1139/X10-107>>.

FU, L.; SUN, H.; SHARMA, R. P.; et al. Nonlinear mixed-effects crown width models for individual trees of Chinese fir (*Cunninghamia lanceolata*) in south-central China. **Forest Ecology and Management**, v. 302, p. 210–220, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.foreco.2013.03.036>>.

GARCIA, N. M.; MACHUCA, M. A. H.; FERREIRA, R. L. C. Modelo para cálculo estimación del carbono en Tipo Forestal Roble-Raulí-Coigüe en la Reserva Nacional Malleco: Chile. **Revista Árvore**, v. 35, n. 6, p. 1299–1306, 2011. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622011000700016&lng=es&tlng=es>.

GARLET, J.; COSTA, E. C.; BOSCARDIN, J. Levantamento da entomofauna em plantios de *Eucalyptus* spp. por meio de armadilha luminosa em São Francisco de Assis - RS. **Ciencia Florestal**, v. 26, n. 2, p. 365–374, 2016. Disponível em: <<http://periodicos.ufsm.br/cienciaflorestal/article/view/22737>>.

GATTO, A.; BARROS, N. F. de; NOVAIS, R. F. de; et al. Estoque de carbono na biomassa de plantações de eucalipto na região centro-leste do estado de Minas Gerais. **Revista Árvore**, v. 35, n. 4, p. 895–905, 2011. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622011000500015&lng=pt&tlng=pt>.

GELMAN, A.; SU, Y. **arm**: data analysis using regression and multilevel/hierarchical models. 2018. Disponível em: <<https://CRAN.R-project.org/package=arm>>.

GONZÁLEZ-GARCÍA, M.; HEVIA, A.; MAJADA, J.; BARRIO-ANTA, M. Above-ground biomass estimation at tree and stand level for short rotation plantations of *Eucalyptus nitens* (Deane & Maiden) Maiden in Northwest Spain. **Biomass and Bioenergy**, v. 54, p. 147–157, 2013. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0961953413001517>>.

GUEDES, B. S.; SITOE, A. A.; OLSSON, B. A. Allometric models for managing lowland miombo woodlands of the Beira corridor in Mozambique. **Global Ecology and Conservation**, v. 13, p. e00374, 2018. Disponível em: <<http://dx.doi.org/10.1016/j.gecco.2018.e00374>>.

GURDAK, D. J.; ARAGÃO, L. E. O. C.; ROZAS-DÁVILA, A.; et al. Assessing above-ground woody debris dynamics along a gradient of elevation in Amazonian cloud forests in Peru: balancing above-ground inputs and respiration outputs. **Plant Ecology & Diversity**, v. 7, n. 1–2, p. 143–160, 2014. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/17550874.2013.818073>>.

HAMNER, B.; FRASCO, M. **Metrics**: evaluation metrics for machine learning. 2018. Disponível em: <<https://CRAN.R-project.org/package=Metrics>>.

HIJMANS, R. J.; CAMERON, S. E.; PARRA, J. L.; JONES, P. G.; JARVIS, A. Very high resolution interpolated climate surfaces for global land areas. **International Journal of Climatology**, v. 25, n. 15, p. 1965–1978, 2005. Disponível em: <<http://doi.wiley.com/10.1002/joc.1276>>.

HJELM, B.; JOHANSSON, T. Volume equations for poplars growing on farmland in Sweden. **Scandinavian Journal of Forest Research**, v. 27, n. 6, p. 561–566, 2012. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/02827581.2012.679678>>.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359–366, 1989. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0893608089900208?via%3Dihub>>.

INDÚSTRIA BRASILEIRA DE ÁRVORES. **Relatório 2017**. Brasília: Studio 113, 2017. Disponível em: <https://iba.org/images/shared/Biblioteca/IBA_RelatorioAnual2017.pdf>.

JELIHOVSCHI, E.; FARIA, J. C.; ALLAMAN, I. B. ScottKnott: A Package for Performing the Scott-Knott Clustering Algorithm in R. **TEMA (São Carlos)**, v. 15, n. 1, p. 003, 2014. Disponível em: <<http://tema.sbmec.org.br/tema/article/view/646>>.

JUNG, Y. Multiple predicting K -fold cross-validation for model selection. **Journal of Nonparametric Statistics**, v. 30, n. 1, p. 197–215, 2018. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/10485252.2017.1404598>>.

KETTERINGS, Q. M.; COE, R.; VAN NOORDWIJK, M.; AMBAGAU', Y.; PALM, C. A. Reducing uncertainty in the use of allometric biomass equations for predicting above-ground tree biomass in mixed secondary forests. **Forest Ecology and Management**, v. 146, n. 1–3, p. 199–209, 2001. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112700004606>>.

KOZAK, A.; KOZAK, R. Does cross validation provide additional information in the evaluation of regression models?. **Canadian Journal of Forest Research**, v. 33, n. 6, p. 976–987, 2003. Disponível em: <<http://www.nrcresearchpress.com/doi/abs/10.1139/x03-022>>.

KRIDIBORWORN, P.; CHIDTHAISONG, A.; YUTTITHAM, M.; TRIPETCHKUL, S. Carbon sequestration by mangrove forest planted specifically for charcoal production in Yeesarn, Samut Songkram. **Journal of Sustainable Energy & Environment**, v. 3, p. 87–92, 2012. Disponível em: <http://www.jgsee.kmutt.ac.th/jsee/JSEE_Vol3No2_2012.html>.

KUSMANA, C.; HIDAYAT, T.; TIRYANA, T.; RUSDIANA, O.; ISTOMO. Allometric models for above- and below-ground biomass of *Sonneratia* spp. **Global Ecology and Conservation**, v. 15, p. e00417, 2018. Disponível em: <<https://doi.org/10.1016/j.gecco.2018.e00417>>.

KUYAH, S.; DIETZ, J.; MUTHURI, C.; et al. Allometric equations for estimating biomass in agricultural landscapes: I. Aboveground biomass. **Agriculture, Ecosystems & Environment**, v. 158, p. 216–224, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.agee.2012.05.011>>.

KUYAH, S.; SILESHI, G.; ROSENSTOCK, T. Allometric models based on bayesian frameworks give better estimates of aboveground biomass in the Miombo Woodlands. **Forests**, v. 7, n. 2, p. 13, 2016. Disponível em: <<http://www.mdpi.com/1999-4907/7/2/13>>.

LAFETÁ, B. O.; SANTANA, R. C.; NOGUEIRA, G. S.; PENIDO, T. M. A.; VIEIRA, D. D. S. Ecophysiology modeling by artificial neural networks for different spacings in eucalypt. **Comunicata Scientiae**, v. 9, n. 3, p. 438–448, 2018. Disponível em: <<https://www.comunicatascientiae.com.br/comunicata/article/view/2741>>.

LELES, P. S. DOS S.; REIS, G. G. DOS; REIS, M. DAS G. F.; MORAIS, E. J. de. Crescimento, produção e alocação de matéria seca de *Eucalyptus camaldulensis* e *E. pellita* sob diferentes espaçamentos na região de cerrado, MG. **Scientia Forestalis**, n. 59, p. 77–87, 2001.

LI, H.; ZHAO, P. Improving the accuracy of tree-level aboveground biomass equations with height classification at a large regional scale. **Forest Ecology and Management**, v. 289, p. 153–163, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.foreco.2012.10.002>>.

LITTON, C. M.; BOONE KAUFFMAN, J. Allometric models for predicting aboveground biomass in two widespread woody plants in Hawaii. **Biotropica**, v. 40, n. 3, p. 313–320, 2008. Disponível em: <<http://doi.wiley.com/10.1111/j.1744-7429.2007.00383.x>>.

LÓPEZ-DÍAZ, M. L.; BENÍTEZ, R.; MORENO, G. How do management techniques affect carbon stock in intensive hardwood plantations?. **Forest Ecology and**

Management, v. 389, p. 228–239, 2017. Disponível em:
<<https://linkinghub.elsevier.com/retrieve/pii/S0378112716305357>>.

MAGALHÃES, T. M. Site-specific height-diameter and stem volume equations for Lebombo-ironwood. **Annals of Forest Research**, v. 60, n. 2, p. 297–312, 2017. Disponível em: <<http://afrjournal.org/index.php/afr/article/view/838>>.

MELLO, S. L. DE M.; GONÇALVES, J. L. DE M. Equações para estimar a biomassa da parte aérea e do sistema radicular em povoamentos de *Eucalyptus grandis* em sítios com produtividades distintas. **Revista Árvore**, v. 32, n. 1, p. 101–111, 2008. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622008000100012&lng=pt&tlng=pt>.

MENSAH, S.; VELDTMAN, R.; DU TOIT, B.; GLÈLÈ KAKAI, R.; SEIFERT, T. Aboveground biomass and carbon in a south african mistbelt forest and the relationships with tree species diversity and forest structures. **Forests**, v. 7, n. 12, p. 79, 2016. Disponível em: <<http://www.mdpi.com/1999-4907/7/4/79>>.

MGANGA, N. D. Investigation of the desirable predictor variable in accounting above-ground carbon for *Pseudolachnostylis maprouneifolia* Pax. (Kudu-Berry). **International Journal of Research in Agriculture and Forestry**, v. 3, n. 1, p. 49–56, 2016. Disponível em:
<<http://repository.udsm.ac.tz:8080/xmlui/handle/123456789/1607>>.

MIKSYS, V.; VARNAGIRYTEKABASINSKIENE, I.; STUPAK, I.; et al. Above-ground biomass functions for Scots pine in Lithuania. **Biomass and Bioenergy**, v. 31, n. 10, p. 685–692, 2007. Disponível em:
<<http://linkinghub.elsevier.com/retrieve/pii/S0961953407001201>>.

MOLTO, Q.; ROSSI, V.; BLANC, L. Error propagation in biomass estimation in tropical forests. **Methods in Ecology and Evolution**, v. 4, n. 2, p. 175–183, 2013. Disponível em: <<http://doi.wiley.com/10.1111/j.2041-210x.2012.00266.x>>.

MONTAGU, K. D.; DÜTTMER, K.; BARTON, C. V. M.; COWIE, A. L. Developing general allometric relationships for regional estimates of carbon sequestration—an example using *Eucalyptus pilularis* from seven contrasting sites. **Forest Ecology and Management**, v. 204, n. 1, p. 115–129, 2005. Disponível em:
<<http://linkinghub.elsevier.com/retrieve/pii/S0378112704006486>>.

NADERPOUR, H.; RAFIEAN, A. H.; FAKHARIAN, P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks. **Journal of Building Engineering**, v. 16, p. 213–219, 2018. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S2352710217306083>>. Acesso em: 21/6/2018.

NAGAR, B.; RAWAT, S.; RATHIESH, P.; SEKAR, I. Impact of initial spacing on growth and yield of *Eucalyptus camaldulensis* in arid region of India. **World Applied Sciences Journal**, v. 33, n. 8, p. 1362–1368, 2015. Disponível em:
<[https://www.idosi.org/wasj/wasj33\(8\)2015.htm](https://www.idosi.org/wasj/wasj33(8)2015.htm)>.

NÁVAR, J. Allometric equations for tree species and carbon stocks for forests of northwestern Mexico. **Forest Ecology and Management**, v. 257, n. 2, p. 427–434, 2009. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S037811270800697X>>.

NELSON, A. S.; WEISKITTEL, A. R.; WAGNER, R. G.; SAUNDERS, M. R. Development and evaluation of aboveground small tree biomass models for naturally regenerated and planted species in eastern Maine, U.S.A. **Biomass and Bioenergy**, v. 68, p. 215–227, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.biombioe.2014.06.015>>.

NIKLAS, K. J.; SPATZ, H.-C. From The Cover: Growth and hydraulic (not mechanical) constraints govern the scaling of tree height and mass. **Proceedings of the National Academy of Sciences**, v. 101, n. 44, p. 15661–15663, 2004. Disponível em: <<http://www.pnas.org/cgi/doi/10.1073/pnas.0405857101>>.

OLIVEIRA, T. W. G. de; LIMA, E. M.; SANQUETTA, C. R.; DALLA CORTE, A. P. Ajuste simultâneo na predição de biomassa aérea em *Araucaria angustifolia* (Bertol.) Kuntze. **BIOFIX Scientific Journal**, v. 3, n. 1, p. 137–144, 2018. Disponível em: <<https://revistas.ufpr.br/biofix/article/view/58119>>.

OUNBAN, W.; PUANGCHIT, L.; DILOKSUMPUN, S. Development of general biomass allometric equations for *Tectona grandis* Linn.f. and *Eucalyptus camaldulensis* Dehnh. plantations in Thailand. **Agriculture and Natural Resources**, v. 50, n. 1, p. 48–53, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.anres.2015.08.001>>.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WİANT, H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, v. 91, n. 3, p. 742–753, 2010. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0301479709003430>>.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; EKER, M.; GÜRLEVIK, N. Artificial neural network models: an alternative approach for reliable aboveground pine tree biomass prediction. **Forest Science**, v. 63, n. 3, p. 291–302, 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2452316X16000107>>.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.; BROOKS, J. The use of tree crown variables in over-bark diameter and volume prediction models. **iForest - Biogeosciences and Forestry**, v. 7, n. 3, p. 132–139, 2014. Disponível em: <<http://www.sisef.it/iforest/?doi=10.3832/ifor0878-007>>.

PAUL, K. I.; ROXBURGH, S. H.; RITSON, P.; et al. Testing allometric equations for prediction of above-ground biomass of mallee eucalypts in southern Australia. **Forest Ecology and Management**, v. 310, p. 1005–1015, 2013. Disponível em: <<http://cascavel.ufsm.br/revistas/ojs-2.2.2/index.php/cienciaflorestal/article/view/2743>>.

PÉLLICO NETTO, S. **Die Forstinventuren in Brasilien**: Neue Entwicklungen und ihr Beitrag für eine geregelte Forstwirtschaft. 232 f. Tese (Doutorado em Biometria e Inventário Florestal) - Universität Freiburg, Freiburg, 1979.

PHIRI, D.; ACKERMAN, P.; WESSELS, B.; et al. Biomass equations for selected drought-tolerant eucalypts in South Africa. **Southern Forests: a Journal of Forest Science**, v. 77, n. 4, p. 255–262, 2015. Disponível em: <<http://www.tandfonline.com/doi/full/10.2989/20702620.2015.1055542>>.

PICARD, N.; RUTISHAUSER, E.; PLOTON, P.; NGOMANDA, A.; HENRY, M. Should tree biomass allometry be restricted to power models? **Forest Ecology and Management**, v. 353, n. 3, p. 156–163, 2015. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0378112715003138>>.

R CORE TEAM. **R**: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2018. Disponível em: <<https://www.R-project.org>>.

RADTKE, P.; WALKER, D.; FRANK, J.; et al. Improved accuracy of aboveground biomass and carbon estimates for live trees in forests of the eastern United States. **Forestry**, v. 90, n. 1, p. 32–46, 2016. Disponível em: <<https://academic.oup.com/forestry/article-lookup/doi/10.1093/forestry/cpw047>>.

RATHORE, A. C.; KUMAR, A.; TOMAR, J. M. S.; et al. Predictive models for biomass and carbon stock estimation in *Psidium guajava* on bouldery riverbed lands in North-Western Himalayas, India. **Agroforestry Systems**, v. 92, n. 1, p. 171–182, 2018. Disponível em: <<http://link.springer.com/10.1007/s10457-016-0023-z>>.

RIBEIRO, S. C.; SOARES, C. P. B.; FEHRMANN, L.; JACOVINE, L. A. G.; VON GADOW, K. Aboveground and belowground biomass and carbon estimates for clonal *Eucalyptus* trees in Southeast Brazil. **Revista Árvore**, v. 39, n. 2, p. 353–363, 2015. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622015000200353&lng=en&tlng=en>.

RICKER, W. E. Growth rates and models. **Bioenergetics and Growth**, v. 8, p. 677–743, 1979. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1546509808600345>>.

ROJAS-GARCÍA, F.; DE JONG, B. H. J.; MARTÍNEZ-ZURIMENDÍ, P.; PAZ-PELLAT, F. Database of 478 allometric equations to estimate biomass for Mexican trees and forests. **Annals of Forest Science**, v. 72, n. 6, p. 835–864, 2015. Disponível em: <<http://link.springer.com/10.1007/s13595-015-0456-y>>.

ROXBURGH, S. H.; PAUL, K. I.; CLIFFORD, D.; ENGLAND, J. R.; RAISON, R. J. Guidelines for constructing allometric models for the prediction of woody biomass: How many individuals to harvest? **Ecosphere**, v. 6, n. 3, 2015. Disponível em: <<http://doi.wiley.com/10.1890/ES14-00251.1>>.

SANQUETTA, C. R.; BEHLING, A.; CORTE, A. P. D.; et al. Estoques de biomassa e carbono em povoamentos de acácia negra em diferentes idades no Rio Grande do Sul. **Scientia Forestalis**, v. 42, n. 103, p. 361–370, 2014. Disponível em: <<http://www.ipef.br/publicacoes/scientia/leitura.asp?Article=06&Number=103&p=s>>.

SANTOS H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; et al. **Sistema brasileiro de classificação de solos**. Brasília: Embrapa; 2013.

SANTOS, F. L.; JESUS, V. A. M. de; VALENTE, D. S. M. Modeling of soil penetration resistance using statistical analyses and artificial neural networks. **Acta Scientiarum**, v. 34, n. 2, p. 219–224, 2012. Disponível em: <<http://periodicos.uem.br/ojs/index.php/ActaSciAgron/article/view/11627>>.

SAWADOGO, L.; SAVADOGO, P.; TIVEAU, D.; et al. Allometric prediction of above-ground biomass of eleven woody tree species in the Sudanian savanna-woodland of West Africa. **Journal of Forestry Research**, v. 21, n. 4, p. 475–481, 2010. Disponível em: <<http://link.springer.com/10.1007/s11676-010-0101-4>>.

SCHMIDT, A.; POULAIN, M.; KLEIN, D.; et al. Allometric above-belowground biomass equations for *Nothofagus pumilio* (Poepp. & Endl.) natural regeneration in the Chilean Patagonia. **Annals of Forest Science**, v. 66, n. 5, 2009. Disponível em: <<http://link.springer.com/10.1051/forest/2009030>>.

SCHMITT, F.; BANU, R.; YEOM, I.-T.; DO, K.-U. Development of artificial neural networks to predict membrane fouling in an anoxic-aerobic membrane bioreactor treating domestic wastewater. **Biochemical Engineering Journal**, v. 133, p. 47–58, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1369703X18300469>>. Acesso em: 23/6/2018.

SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the analysis of variance. **Biometrics**, v. 30, n. 3, p. 507, 1974. Disponível em: <<https://www.jstor.org/stable/2529204?origin=crossref>>.

SENA, A. L. M.; SILVA NETO, A. J. da; OLIVEIRA, G. M. V.; CALEGARIO, N. Modelos lineares e não lineares com uso de covariantes para relação hipsométrica de duas espécies de pinus tropicais. **Ciência Florestal**, v. 25, n. 4, p. 969–980, 2015. Disponível em: <<http://cascavel.ufsm.br/revistas/ojs-2.2.2/index.php/cienciaflorestal/article/view/20651>>.

SHAHROKHZADEH, U.; SOHRABI, H.; COPENHEAVER, C. A. Aboveground biomass and leaf area equations for three common tree species of Hyrcanian temperate forests in northern Iran. **Botany**, v. 93, n. 10, p. 663–670, 2015. Disponível em: <<http://www.nrcresearchpress.com/doi/10.1139/cjb-2015-0078>>.

SHAPIRO, S. S.; WILK, M. B. Approximations for the null distribution of the w statistic. **Technometrics**, v. 10, n. 4, p. 861–866, 1968. Disponível em: <<https://www.jstor.org/stable/1267467?origin=crossref>>.

SHARIFI, A.; AMINI, J.; POURSHAKOURI, F. Development of an allometric model to estimate above-ground biomass of forests using MLPNN algorithm, case study: Hyrcanian forests of Iran. **Caspian Journal of Environmental Sciences**, v. 14, n. 2, p. 125–137, 2016. Disponível em: <http://cjes.guilan.ac.ir/article_1769.html>.

SHARMA, R. P.; BHANDARI, S. K.; BK, R. B. Allometric bark biomass model for *Daphne bholua* in the Mid-Hills of Nepal. **Mountain Research and Development**, v. 37, n. 2, p. 206–215, 2017. Disponível em: <<http://www.bioone.org/doi/10.1659/MRD-JOURNAL-D-16-00052.1>>.

SHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v. 47, n. 9, p. 719–734, 1933. Disponível em: <<https://naldc.nal.usda.gov/download/IND43968352/PDF>>.

SILESHI, G. W. A critical review of forest biomass estimation models, common mistakes and corrective measures. **Forest Ecology and Management**, v. 329, p. 237–254, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.foreco.2014.06.026>>.

SILVA, C. A.; KLAUBERG, C.; E CARVALHO, S. D. P. C.; PICCOLO, M. D. C.; RODRIGUEZ, L. C. E. Estoque de carbono na biomassa aérea florestal em plantações comerciais de *Eucalyptus* spp. **Scientia Forestalis**, v. 43, n. 105, p. 135–146, 2015. Disponível em: <<http://www.ipef.br/publicacoes/scientia/leitura.asp?Article=13&Number=105&p=s>>.

SISTEMA DE PROTEÇÃO DA AMAZÔNIA. **Zoneamento climático do Estado do Pará**. Belém: Centro Técnico e Operacional de Belém, 2009.

SOARES, C. P. B.; OLIVEIRA, M. L. R. de. Equações para estimar a quantidade de carbono na parte aérea de árvores de eucalipto em Viçosa, Minas Gerais. **Revista Árvore**, v. 26, n. 5, p. 533–539, 2002. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622002000500002&lng=pt&tlng=pt>.

SOARES, T. S.; GOUVEIA JUNIOR, W. V.; MATIAS, R. A. M.; CRUZ, E. S. Effect of stocking density on energetic productivity of an *Eucalyptus* stands managed under a short rotation system. **Nativa**, v. 6, n. 2, p. 165–169, 2018. Disponível em: <<http://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/view/4767>>.

SOHRABI, H.; BAKHTIARVAND-BAKHTIARI, S.; AHMADI, K. Above- and below-ground biomass and carbon stocks of different tree plantations in central Iran. **Journal of Arid Land**, v. 8, n. 1, p. 138–145, 2016. Disponível em: <<http://link.springer.com/10.1007/s40333-015-0087-z>>.

SOKAL, R. R.; MICHENER, C. D. A statistical method for evaluating systematic relationships. **The University of Kansas science bulletin**, v. 38, p. 1409–1438, 1958. Disponível em: <<https://www.biodiversitylibrary.org/item/23745#page/387/mode/1up>>.

SOKAL, R. R.; ROHLF, F. J. The Comparison of dendrograms by objective methods. **Taxon**, v. 11, n. 2, p. 33, 1962. Disponível em: <<https://www.jstor.org/stable/1217208?origin=crossref>>.

STURGES, H. A. The Choice of a Class Interval. **Journal of the American Statistical Association**, v. 21, n. 153, p. 65–66, 1926. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01621459.1926.10502161>>.

SUBEDI, M. R.; SHARMA, R. P. Allometric biomass models for bark of *Cinnamomum tamala* in mid-hill of Nepal. **Biomass and Bioenergy**, v. 47, p. 44–49, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.biombioe.2012.10.006>>.

THE H2O.ai TEAM. **h2o**: R Interface for H2O. 2017. Disponível em: <<https://CRAN.R-project.org/package=h2o>>.

TSCHIEDER, E. F.; FERNÁNDEZ, M. E.; SCHLICHTER, T. M.; PINAZO, M. A.; CRECHI, E. H. Influence of growth dominance and individual tree growth efficiency on *Pinus taeda* stand growth. A contribution to the debate about why stands productivity declines. **Forest Ecology and Management**, v. 277, n. 1–3, p. 116–123, 2012. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112712002344>>.

ULLAH, M. R.; AL-AMIN, M. Above- and below-ground carbon stock estimation in a natural forest of Bangladesh. **Journal of Forest Science**, v. 58, n. No. 8, p. 372–379, 2012. Disponível em: <<http://www.agriculturejournals.cz/web/jfs.htm?volume=58&firstPage=372&type=publishedArticle>>.

VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, v. 88, n. 1, p. 66–76, 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0961953416300691>>.

VAHEDI, A. A. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. **CATENA**, v. 152, p. 182–189, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.catena.2017.01.022>>.

VANCLAY, J. K. **Modelling forest growth and yield**: applications to mixed tropical forests. Oxon: CAB International, 1994. Disponível em: <https://epubs.scu.edu.au/cgi/viewcontent.cgi?referer=https://scholar.google.com/&httpsredir=1&article=1538&context=esm_pubs>.

VANCLAY, J. K.; SKOVSGAARD, J. P. Evaluating forest growth models. **Ecological Modelling**, v. 98, n. 1, p. 1–12, 1997. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0304380096019321>>.

VARGAS-LARRETA, B.; LÓPEZ-SÁNCHEZ, C. A.; CORRAL-RIVAS, J. J.; et al. Allometric equations for estimating biomass and carbon stocks in the temperate

forests of North-Western Mexico. **Forests**, v. 8, n. 8, p. 269, 2017. Disponível em: <<http://www.mdpi.com/1999-4907/8/8/269>>.

VENABLES, W. N.; RIPLAY, B. D. **Modern Applied Statistics with S**. New York: Springer, 2002. Disponível em: <<http://www.stats.ox.ac.uk/pub/MASS4/>>.

VERMA, A.; KAUSHAL, R.; ALAM, N. M.; et al. Predictive models for biomass and carbon stocks estimation in *Grewia optiva* on degraded lands in western Himalaya. **Agroforestry Systems**, v. 88, n. 5, p. 895–905, 2014.

VIERA, M.; SCHUMACHER, M. V.; TRÜBY, P.; ARAÚJO, E. F. Biomassa e Nutrientes em Um Povoamento de *Eucalyptus urophylla* x *Eucalyptus globulus*, em Eldorado do Sul-RS. **Revista Ecologia e Nutrição Florestal**, v. 1, n. 1, p. 1–13, 2013. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-77602013000300018&lng=pt&tlng=pt%0Ahttp://www.bibliotekevirtual.org/index.php/2013-02-07-03-02-35/2013-02-07-03-03-11/168-enflo/v01n01/521-v01n01a01.html>.

WAYSON, C. A.; JOHNSON, K. D.; COLE, J. A.; et al. Estimating uncertainty of allometric biomass equations with incomplete fit error information using a pseudo-data approach: methods. **Annals of Forest Science**, v. 72, n. 6, p. 825–834, 2015. Disponível em: <<http://link.springer.com/10.1007/s13595-014-0436-7>>.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v. 1, n. 1, p. 9–23, 2008. Disponível em: <<https://academic.oup.com/jpe/article-lookup/doi/10.1093/jpe/rtm005>>.

ZHAO, D.; KANE, M.; MARKEWITZ, D.; TESKEY, R.; CLUTTER, M. Additive tree biomass equations for midrotation loblolly pine plantations. **Forest Science**, v. 61, n. 4, p. 613–623, 2015. Disponível em: <<https://academic.oup.com/forestscience/article/61/4/613-623/4583831>>.

ZHI, L.-H.; HU, P.; CHEN, L.-X.; ZHAO, G. Viscosity prediction for six pure refrigerants using different artificial neural networks. **International Journal of Refrigeration**, v. 88, p. 432–440, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0140700718300574>>. Acesso em: 22/6/2018.

ZIANIS, D.; MENCUCCINI, M. Aboveground biomass relationships for beech (*Fagus moesiaca* Cz.) trees in Vermio Mountain, Northern Greece, and generalised equations for *Fagus* sp. **Annals of Forest Science**, v. 60, n. 5, p. 439–448, 2003. Disponível em: <<http://www.edpsciences.org/10.1051/forest:2003036>>.

APÊNDICE 1 – ANÁLISES DE VARIÂNCIA POR MATERIAIS GENÉTICOS

TABELA 46 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE FOLHAS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	113,8093	22,7619	43,3379*	22,9126
Materiais genéticos	9	40,8747	4,5416	8,6471*	
Erro experimental	45	23,6348	0,5252		
Total	59	178,3188			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 47 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE GALHOS VIVOS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	171,3563	34,2713	49,0547*	19,9868
Materiais genéticos	9	80,3914	8,9324	12,7855*	
Erro experimental	45	31,4385	0,6986		
Total	59	283,1862			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 48 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE GALHOS SECOS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	27,2040	5,4408	7,9409*	32,3009
Materiais genéticos	9	72,7046	8,0783	11,7903*	
Erro experimental	45	30,8325	0,6852		
Total	59	130,7412			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 49 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE CASCA POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	272,2437	54,4487	105,7126*	10,5329
Materiais genéticos	9	142,3774	15,8197	30,7141*	
Erro experimental	45	23,1779	0,5151		
Total	59	437,7990			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 50 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE LENHO POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	40500,7108	8100,1422	116,592*	10,9258
Materiais genéticos	9	12830,0640	1425,5627	20,5193*	
Erro experimental	45	3126,3403	69,4742		
Total	59	56457,1152			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 51 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO TOTAL DOS COMPONENTES POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	60655,0650	12131,0130	149,1893*	9,6951
Materiais genéticos	9	17932,7979	1992,5331	24,5045*	
Erro experimental	45	3659,0801	81,3129		
Total	59	82246,9431			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 52 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE COPA POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	824,1780	164,8356	55,8859*	17,3343
Materiais genéticos	9	290,5720	32,2858	10,9462*	
Erro experimental	45	132,7276	2,9495		
Total	59	1247,4775			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 53 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE TRONCO POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	47394,5762	9478,9152	125,0838*	10,4753
Materiais genéticos	9	14628,9991	1625,4443	21,4494*	
Erro experimental	45	3410,1220	75,7805		
Total	59	65433,6973			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 54 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	28,0567	5,6113	44,9199*	22,7184
Materiais genéticos	9	9,9072	1,1008	8,8121*	
Erro experimental	45	5,6213	0,1249		
Total	59	43,5852			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 55 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	31,1225	6,2245	46,0211*	20,5921
Materiais genéticos	9	14,8207	1,6467	12,1753*	
Erro experimental	45	6,0864	0,1353		
Total	59	52,0295			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 56 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	6,2029	1,2406	8,7659*	31,6996
Materiais genéticos	9	15,6341	1,7371	12,2744*	
Erro experimental	45	6,3686	0,1415		
Total	59	28,2056			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 57 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	46,1769	9,2354	107,878*	10,3578
Materiais genéticos	9	29,3010	3,2557	38,0293*	
Erro experimental	45	3,8524	0,0856		
Total	59	79,3304			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 58 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	7900,3371	1580,0674	112,0364*	11,1097
Materiais genéticos	9	2471,1337	274,5704	19,4687*	
Erro experimental	45	634,6420	14,1032		
Total	59	11006,1128			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 59 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	11827,1992	2365,4398	146,3569*	9,7682
Materiais genéticos	9	3521,6796	391,2977	24,2108*	
Erro experimental	45	727,2959	16,1621		
Total	59	16076,1748			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 60 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	173,3658	34,6732	55,7791*	17,4105
Materiais genéticos	9	58,5504	6,5056	10,4656*	
Erro experimental	45	27,9727	0,6216		
Total	59	259,8889			

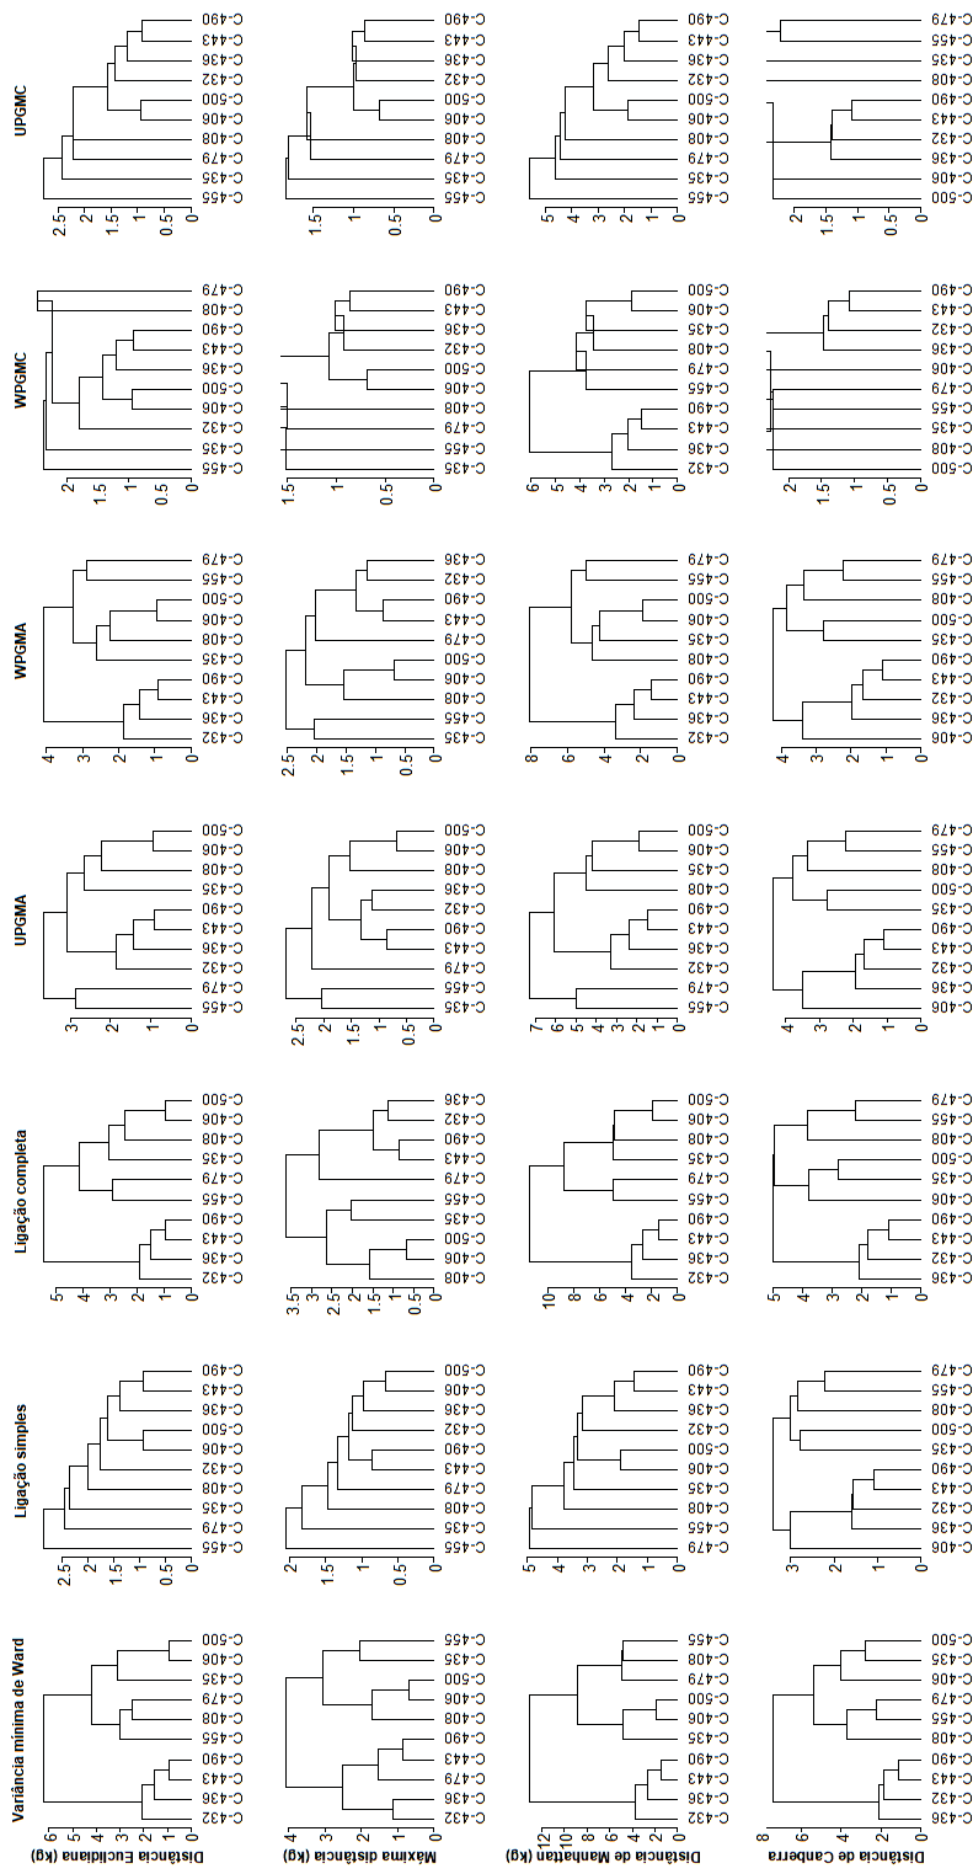
G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 61 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO POR MATERIAL GENÉTICO

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	9146,5455	1829,3091	122,0518*	10,5696
Materiais genéticos	9	2856,6361	317,4040	21,1772*	
Erro experimental	45	674,4590	14,9880		
Total	59	12677,6405			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

FIGURA 30 – TODOS OS DENDROGRAMAS OBTIDOS POR ANÁLISE DE AGRUPAMENTO EM FUNÇÃO DA MÉDIA DO CARBONO ORGÂNICO ESTOCADO NOS DIFERENTES COMPONENTES



APÊNDICE 3 – ANÁLISES DE VARIÂNCIA POR GRUPOS DE MATERIAIS GENÉTICOS

TABELA 62 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE FOLHAS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	113,8093	22,7619	27,7401*	28,6388
Grupos de materiais genéticos	3	22,6619	7,5540	9,2061*	
Erro experimental	51	41,8476	0,8205		
Total	59	178,3188			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 63 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE GALHOS VIVOS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	171,3563	34,2713	34,4864*	23,8374
Grupos de materiais genéticos	3	61,1481	20,3827	20,5107*	
Erro experimental	51	50,6818	0,9938		
Total	59	283,1862			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 64 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE GALHOS SECOS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	27,2040	5,4408	5,2982*	39,5445
Grupos de materiais genéticos	3	51,1640	17,0547	16,6075*	
Erro experimental	51	52,3731	1,0269		
Total	59	130,7412			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 65 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE CASCA POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	272,2437	54,4487	43,7178*	16,3788
Grupos de materiais genéticos	3	102,0369	34,0123	27,309*	
Erro experimental	51	63,5184	1,2455		
Total	59	437,7990			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 66 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE LENHO POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	40500,7108	8100,1422	76,0577*	13,5275
Grupos de materiais genéticos	3	10524,9057	3508,3019	32,9418*	
Erro experimental	51	5431,4987	106,5000		
Total	59	56457,1152			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 67 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO TOTAL DOS COMPONENTES POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	60655,0650	12131,0130	97,7469*	11,9776
Grupos de materiais genéticos	3	15262,4538	5087,4846	40,9929*	
Erro experimental	51	6329,4242	124,1064		
Total	59	82246,9431			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 68 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE COPA POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	824,1780	164,8356	41,4325*	20,1321
Grupos de materiais genéticos	3	220,4003	73,4668	18,4663*	
Erro experimental	51	202,8993	3,9784		
Total	59	1247,4775			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 69 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA A BIOMASSA SECA DO COMPONENTE TRONCO POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	47394,5762	9478,9152	79,8545*	13,1105
Grupos de materiais genéticos	3	11985,2995	3995,0998	33,6564*	
Erro experimental	51	6053,8216	118,7024		
Total	59	65433,6973			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 70 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	28,0567	5,6113	27,9727*	28,7892
Grupos de materiais genéticos	3	5,2979	1,7660	8,8034*	
Erro experimental	51	10,2306	0,2006		
Total	59	43,5852			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 71 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	31,1225	6,2245	32,7277*	24,4186
Grupos de materiais genéticos	3	11,2074	3,7358	19,6424*	
Erro experimental	51	9,6997	0,1902		
Total	59	52,0295			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 72 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	6,2029	1,2406	5,8394*	38,8391
Grupos de materiais genéticos	3	11,1676	3,7225	17,5218*	
Erro experimental	51	10,8350	0,2125		
Total	59	28,2056			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 73 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	46,1769	9,2354	30,1431*	19,5947
Grupos de materiais genéticos	3	17,5278	5,8426	19,0694*	
Erro experimental	51	15,6256	0,3064		
Total	59	79,3304			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 74 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	7900,3371	1580,0674	75,6736*	13,5179
Grupos de materiais genéticos	3	2040,8944	680,2981	32,5813*	
Erro experimental	51	1064,8813	20,8800		
Total	59	11006,1128			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 75 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	11827,1992	2365,4398	96,7988*	12,0112
Grupos de materiais genéticos	3	3002,7052	1000,9017	40,9590*	
Erro experimental	51	1246,2704	24,4367		
Total	59	16076,1748			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 76 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	173,3658	34,6732	41,9347*	20,0798
Grupos de materiais genéticos	3	44,3544	14,7848	17,8812*	
Erro experimental	51	42,1687	0,8268		
Total	59	259,8889			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

TABELA 77 – RESULTADOS OBTIDOS NA ANÁLISE DE VARIÂNCIA PARA O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO POR GRUPOS DE MATERIAIS GENÉTICOS

F.V.	G.L.	S.Q.	Q.M.	F	CV%
Classes diamétricas	5	9146,5455	1829,3091	78,9011*	13,1459
Grupos de materiais genéticos	3	2348,6682	782,8894	33,7673*	
Erro experimental	51	1182,4269	23,1848		
Total	59	12677,6405			

G.L. é os graus de liberdade, S.Q. é a soma dos quadrados, Q.M. é o quadrado médio, F é o valor calculado do teste de Fisher, * indica que o valor calculado apresenta significância abaixo de 5% ($p_{\text{value}} \leq 0,05$), e CV% é o coeficiente de variação do experimento, em %. FONTE: O autor (2019).

APÊNDICE 4 – QUALIDADE DAS ESTIMATIVAS PARA O CONJUNTO DE AJUSTE/TREINAMENTO DAS DEMAIS EQUAÇÕES

TABELA 78 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Michaelis-Menten	1,045420	33,02	0,8220	0,9225	< 0,05	$y = 0,623931x + 1,239906$
	Exponencial	1,027411	32,45	0,8265	0,9217	< 0,05	$y = 0,660571x + 1,097260$
	Spurr	1,028099	32,47	0,8258	0,9140	< 0,05	$y = 0,674270x + 1,039073$
	Hjelm-Johansson	1,026213	32,42	0,8264	0,9109	< 0,05	$y = 0,681770x + 1,009371$
Carbono	Michaelis-Menten	0,518783	33,37	0,8180	0,9246	< 0,05	$y = 0,613852x + 0,626029$
	Exponencial	0,509414	32,76	0,8227	0,9253	< 0,05	$y = 0,652143x + 0,552983$
	Spurr	0,508580	32,71	0,8228	0,9191	< 0,05	$y = 0,667214x + 0,522340$
	Hjelm-Johansson	0,508072	32,68	0,8231	0,9153	< 0,05	$y = 0,676998x + 0,502835$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 79 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Michaelis-Menten	1,002187	24,09	0,8962	0,9421	< 0,05	$y = 0,771720x + 0,986230$
	Exponencial	0,983103	23,63	0,8996	0,9579	0,1415	$y = 0,804835x + 0,817253$
	Spurr	1,043955	25,09	0,8863	0,9750	0,5090	$y = 0,807047x + 0,775715$
	Péllico Netto	1,018391	24,48	0,8919	0,9669	0,2850	$y = 0,807938x + 0,783587$
Carbono	Michaelis-Menten	0,439099	24,71	0,8914	0,9481	0,0655	$y = 0,766616x + 0,428723$
	Exponencial	0,432650	24,35	0,8941	0,9650	0,2465	$y = 0,796266x + 0,363636$
	Spurr	0,454553	25,58	0,8828	0,9788	0,6438	$y = 0,802254x + 0,338917$
	Péllico Netto	0,444248	25,00	0,8881	0,9681	0,3126	$y = 0,799615x + 0,350203$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 80 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	1,456270	52,13	0,4917	0,9532	0,0980	$y = 0,239618x + 2,126394$
	Monomolecular incompleto	1,455504	52,10	0,4925	0,9517	0,0870	$y = 0,239810x + 2,126465$
	Spurr	1,478898	52,94	0,4669	0,9575	0,1373	$y = 0,219120x + 2,180407$
	Péllico Netto	1,491172	53,38	0,4552	0,9579	0,1414	$y = 0,228154x + 2,133077$
Carbono	Logístico	0,673123	52,10	0,4943	0,9565	0,1267	$y = 0,242234x + 0,980046$
	Monomolecular incompleto	0,672730	52,07	0,4952	0,9563	0,1249	$y = 0,243185x + 0,978786$
	Spurr	0,683478	52,90	0,4700	0,9614	0,1865	$y = 0,222565x + 1,003715$
	Péllico Netto	0,688785	53,31	0,4592	0,9601	0,1686	$y = 0,231129x + 0,983039$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 81 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	1,252472	17,96	0,9058	0,9658	0,2631	$y = 0,821648x + 1,242519$
	Exponencial	1,378225	19,76	0,8856	0,9240	< 0,05	$y = 0,749694x + 1,787104$
	Péllico Netto	1,341153	19,23	0,8914	0,9428	< 0,05	$y = 0,812537x + 1,284505$
	Hjelm-Johansson	1,376383	19,73	0,8850	0,9446	< 0,05	$y = 0,777696x + 1,559582$
Carbono	Logístico	0,556147	19,14	0,8974	0,9395	< 0,05	$y = 0,807959x + 0,556571$
	Exponencial	0,614530	21,15	0,8743	0,8947	< 0,05	$y = 0,727932x + 0,809340$
	Péllico Netto	0,600463	20,67	0,8795	0,9089	< 0,05	$y = 0,791497x + 0,595763$
	Hjelm-Johansson	0,627308	21,59	0,8674	0,9244	< 0,05	$y = 0,748831x + 0,732912$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 82 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	6,751886	8,67	0,9790	0,9868	0,9146	$y = 0,950847x + 3,93096$
	Exponencial	7,449489	9,57	0,9746	0,9695	0,3477	$y = 0,925655x + 6,11855$
	Spurr	5,451705	7,00	0,9863	0,9814	0,7402	$y = 0,969254x + 2,44343$
	Péllico Netto	5,445361	6,99	0,9863	0,9798	0,6828	$y = 0,971132x + 2,27176$
Carbono	Logístico	2,976285	8,63	0,9789	0,9765	0,5612	$y = 0,950617x + 1,74898$
	Exponencial	3,288481	9,54	0,9745	0,9594	0,1593	$y = 0,925295x + 2,72082$
	Spurr	2,419631	7,02	0,9861	0,9877	0,9357	$y = 0,968624x + 1,10465$
	Péllico Netto	2,415025	7,01	0,9862	0,9876	0,9339	$y = 0,971144x + 1,00295$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 83 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	7,244731	7,63	0,9835	0,9876	0,9324	$y = 0,960842x + 3,825740$
	Exponencial	8,269585	8,71	0,9788	0,9905	0,9802	$y = 0,933433x + 6,723130$
	Schumacher-Hall	6,394675	6,74	0,9872	0,9628	0,2086	$y = 0,970193x + 2,902220$
	Hjelm-Johansson	6,837504	7,20	0,9853	0,9722	0,4205	$y = 0,968130x + 3,075070$
Carbono	Michaelis-Menten	3,907611	9,30	0,9768	0,9815	0,7436	$y = 0,903459x + 4,407410$
	Exponencial	3,698343	8,81	0,9782	0,9870	0,9200	$y = 0,931941x + 3,037750$
	Schumacher-Hall	2,889092	6,88	0,9865	0,9667	0,2821	$y = 0,968271x + 1,369280$
	Hjelm-Johansson	3,120378	7,43	0,9843	0,9687	0,3268	$y = 0,966088x + 1,446180$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 84 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Michaelis-Menten	2,164729	21,39	0,8954	0,9389	< 0,05	$y = 0,770396x + 2,393026$
	Exponencial	2,138769	21,13	0,8974	0,9485	0,0673	$y = 0,794037x + 2,109998$
	Spurr	2,292393	22,65	0,8811	0,9445	< 0,05	$y = 0,787641x + 2,122287$
	Péllico Netto	2,272700	22,46	0,8835	0,9481	0,0651	$y = 0,799811x + 1,979785$
Carbono	Michaelis-Menten	0,988247	21,37	0,8951	0,9382	< 0,05	$y = 0,769172x + 1,099440$
	Exponencial	0,976502	21,12	0,8970	0,9475	0,0623	$y = 0,792675x + 0,970979$
	Spurr	1,040170	22,50	0,8822	0,9436	< 0,05	$y = 0,788885x + 0,964727$
	Péllico Netto	1,032274	22,33	0,8843	0,9453	0,0524	$y = 0,800612x + 0,901681$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 85 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR

Variável	Modelo	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
		kg	(%)		SW	p _{value}	
Biomassa	Logístico	6,674040	7,87	0,9823	0,9831	0,8011	$y = 0,958036x + 3,663200$
	Exponencial	7,660496	9,03	0,9771	0,9674	0,2973	$y = 0,928754x + 6,419134$
	Schumacher-Hall	5,460678	6,44	0,9882	0,9723	0,4244	$y = 0,971474x + 2,495601$
	Péllico Netto	5,433395	6,41	0,9883	0,9584	0,1478	$y = 0,976681x + 1,979360$
Carbono	Logístico	2,956186	7,91	0,9820	0,9795	0,6707	$y = 0,957314x + 1,641524$
	Exponencial	3,399840	9,10	0,9766	0,9652	0,2519	$y = 0,927487x + 2,876505$
	Schumacher-Hall	2,465792	6,60	0,9875	0,9846	0,8519	$y = 0,969362x + 1,183341$
	Péllico Netto	2,452794	6,56	0,9877	0,9803	0,7017	$y = 0,975724x + 0,905581$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 86 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-3-1	85	0,760693	24,03	0,9099	0,9324	< 0,05	$y = 0,794205x + 0,601816$
	11-4-1	69	0,783302	24,74	0,9035	0,9228	< 0,05	$y = 0,791843x + 0,630149$
	12-3-1	123	0,648648	20,49	0,9374	0,9368	< 0,05	$y = 0,811196x + 0,572798$
	12-4-1	84	0,786519	24,84	0,9038	0,9324	< 0,05	$y = 0,767589x + 0,714651$
Carbono	11-3-1	76	0,388642	25,00	0,9018	0,9429	< 0,05	$y = 0,783284x + 0,309367$
	11-4-1	69	0,387005	24,89	0,9021	0,9306	< 0,05	$y = 0,790983x + 0,311290$
	12-3-1	123	0,315538	20,29	0,9384	0,9336	< 0,05	$y = 0,814846x + 0,276587$
	12-4-1	84	0,386039	24,83	0,9038	0,9318	< 0,05	$y = 0,768089x + 0,351449$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 87 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-4-1	57	0,926616	22,27	0,9116	0,9576	0,14	$y = 0,814556x + 0,738696$
	11-3-1	50	1,083704	26,05	0,8767	0,9331	< 0,05	$y = 0,759657x + 0,954562$
	12-3-1	84	0,883498	21,24	0,9211	0,9155	< 0,05	$y = 0,803080x + 0,791909$
	12-5-1	67	0,848469	20,39	0,9271	0,9332	< 0,05	$y = 0,825948x + 0,685900$
Carbono	11-5-1	32	0,434099	24,43	0,8936	0,9661	0,27	$y = 0,785671x + 0,365869$
	11-3-1	50	0,477263	26,86	0,8696	0,9312	< 0,05	$y = 0,749706x + 0,428327$
	12-3-1	92	0,374867	21,10	0,9230	0,9103	< 0,05	$y = 0,806158x + 0,337704$
	12-5-1	67	0,373441	21,02	0,9231	0,9235	< 0,05	$y = 0,818201x + 0,305945$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 88 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-4-1	28	1,140031	40,81	0,7361	0,9615	0,19	$y = 0,482801x + 1,424755$
	11-5-1	33	1,137263	40,71	0,7385	0,9531	0,10	$y = 0,481413x + 1,416762$
	12-6-1	81	0,908007	32,50	0,8430	0,9643	0,23	$y = 0,650963x + 0,939969$
	12-4-1	111	0,921767	32,99	0,8381	0,9561	0,12	$y = 0,636629x + 1,015893$
Carbono	11-4-1	35	0,502437	38,89	0,7661	0,9635	0,22	$y = 0,518732x + 0,614602$
	11-5-1	33	0,521604	40,37	0,7446	0,9518	0,09	$y = 0,488390x + 0,646030$
	12-6-1	81	0,419898	32,50	0,8434	0,9659	0,27	$y = 0,652466x + 0,432296$
	12-4-1	107	0,429247	33,22	0,8364	0,9566	0,13	$y = 0,631053x + 0,468900$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 89 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-4-1	87	1,161522	16,65	0,9198	0,9809	0,72	$y = 0,830404x + 1,150653$
	11-3-1	86	1,225836	17,58	0,9103	0,9758	0,54	$y = 0,808378x + 1,312782$
	12-5-1	189	0,585154	8,39	0,9803	0,9797	0,68	$y = 0,945087x + 0,378604$
	12-4-1	149	0,757623	10,86	0,9670	0,9520	0,09	$y = 0,908876x + 0,631268$
Carbono	11-3-1	87	0,503288	17,32	0,9171	0,9701	0,36	$y = 0,821655x + 0,512573$
	11-4-1	99	0,471821	16,24	0,9276	0,9714	0,40	$y = 0,839584x + 0,453946$
	12-5-1	199	0,284010	9,77	0,9746	0,9583	0,15	$y = 0,926624x + 0,208876$
	12-4-1	144	0,428921	14,76	0,9408	0,9538	0,10	$y = 0,858853x + 0,405080$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 90 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-3-1	85	7,671082	9,85	0,9728	0,9489	0,07	$y = 0,935976x + 4,768202$
	11-4-1	46	8,561432	11,00	0,9660	0,9913	0,99	$y = 0,944400x + 4,289057$
	12-5-1	152	4,521029	5,81	0,9906	0,9545	0,11	$y = 0,973378x + 1,939094$
	12-3-1	175	5,198916	6,68	0,9877	0,9388	< 0,05	$y = 0,964892x + 2,417079$
Carbono	11-3-1	90	3,286257	9,53	0,9742	0,9561	0,12	$y = 0,941932x + 1,929082$
	11-4-1	60	3,420390	9,92	0,9721	0,9860	0,89	$y = 0,948721x + 1,613560$
	12-3-1	163	2,457603	7,13	0,9857	0,9367	< 0,05	$y = 0,961405x + 1,222473$
	12-5-1	88	2,823727	8,19	0,9810	0,9583	0,15	$y = 0,956962x + 1,453704$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 91 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}^{\wedge}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-3-1	91	8,540869	9,00	0,9770	0,9495	0,07	$y = 0,946132x + 4,802476$
	11-6-1	77	8,976275	9,45	0,9746	0,9716	0,40	$y = 0,954041x + 4,122875$
	12-3-1	201	5,561549	5,86	0,9904	0,9453	0,05	$y = 0,971504x + 2,350451$
	12-4-1	125	6,092568	6,42	0,9885	0,9152	< 0,05	$y = 0,966887x + 2,733701$
Carbono	11-3-1	109	3,428844	8,16	0,9810	0,9442	< 0,05	$y = 0,953883x + 1,822362$
	11-6-1	85	3,741642	8,91	0,9773	0,9680	0,31	$y = 0,956285x + 1,678940$
	12-5-1	131	2,478264	5,90	0,9902	0,9570	0,13	$y = 0,969927x + 1,121319$
	12-4-1	125	2,730108	6,50	0,9881	0,9081	< 0,05	$y = 0,966319x + 1,248233$

REQM é a raiz do erro quadrático médio, r_{yy}^{\wedge} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

TABELA 92 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-4-1	47	1,829023	18,07	0,9261	0,9755	0,53	$y = 0,854014x + 1,405310$
	11-3-1	42	1,914916	18,92	0,9189	0,9865	0,91	$y = 0,841899x + 1,484868$
	12-3-1	91	1,600581	15,82	0,9446	0,9805	0,71	$y = 0,857792x + 1,397773$
	12-5-1	67	1,724249	17,04	0,9350	0,9700	0,36	$y = 0,845891x + 1,521113$
Carbono	11-4-1	47	0,823134	17,80	0,9280	0,9764	0,56	$y = 0,857791x + 0,626746$
	11-3-1	38	0,875438	18,93	0,9183	0,9892	0,96	$y = 0,838942x + 0,693472$
	12-3-1	93	0,724778	15,68	0,9453	0,9865	0,91	$y = 0,859572x + 0,638662$
	12-4-1	76	0,771899	16,69	0,9375	0,9497	0,07	$y = 0,848862x + 0,677924$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).

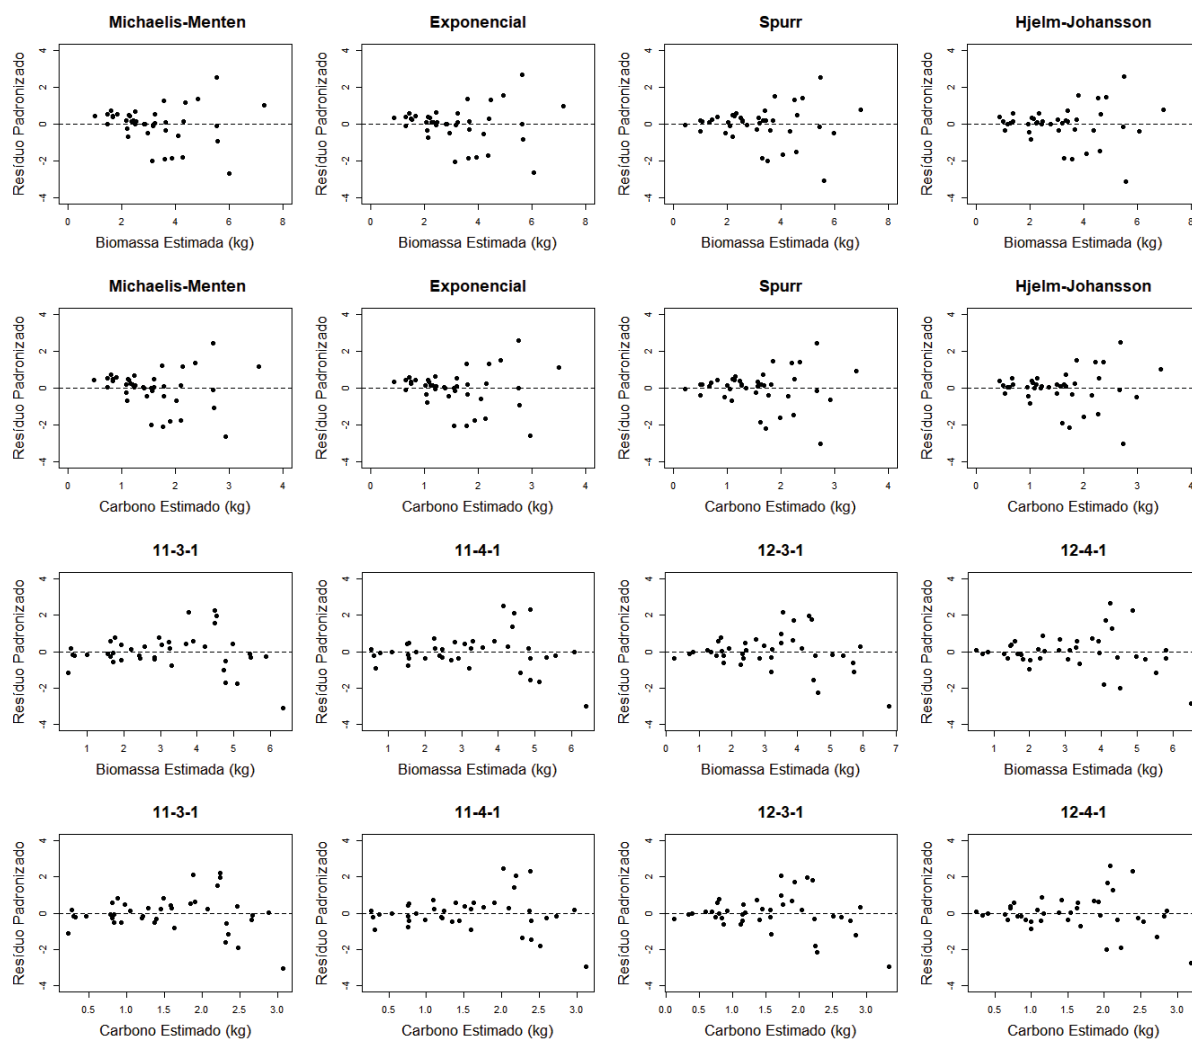
TABELA 93 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR RNA

Variável	Arquitetura	Ciclos	REQM		r_{yy}	Shapiro-Wilk		Equação
			kg	(%)		SW	p _{value}	
Biomassa	11-3-1	75	8,713491	10,27	0,9697	0,9648	0,24	$y = 0,932372x + 5,620833$
	11-6-1	74	8,433324	9,94	0,9716	0,9781	0,62	$y = 0,948043x + 4,247530$
	12-5-1	152	4,603678	5,43	0,9917	0,9578	0,14	$y = 0,976705x + 1,879766$
	12-3-1	196	5,114003	6,03	0,9898	0,9426	< 0,05	$y = 0,969895x + 2,155856$
Carbono	11-3-1	85	3,629056	9,71	0,9728	0,9658	0,26	$y = 0,937249x + 2,255093$
	11-6-1	84	3,492756	9,35	0,9748	0,9763	0,55	$y = 0,951411x + 1,711652$
	12-5-1	152	2,139332	5,72	0,9906	0,9530	0,10	$y = 0,974966x + 0,899313$
	12-3-1	202	2,275927	6,09	0,9895	0,9342	< 0,05	$y = 0,970071x + 0,975815$

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, SW é o valor calculado do teste de Shapiro e Wilk, p_{value} é a significância do teste de Shapiro e Wilk, o y na equação representa o valor estimado, em kg, e o x na equação representa o valor observado, em kg. FONTE: O autor (2019).


APÊNDICE 5 – GRÁFICOS DE RESÍDUOS PARA O CONJUNTO DE AJUSTE/TREINAMENTO DAS DEMAIS EQUAÇÕES

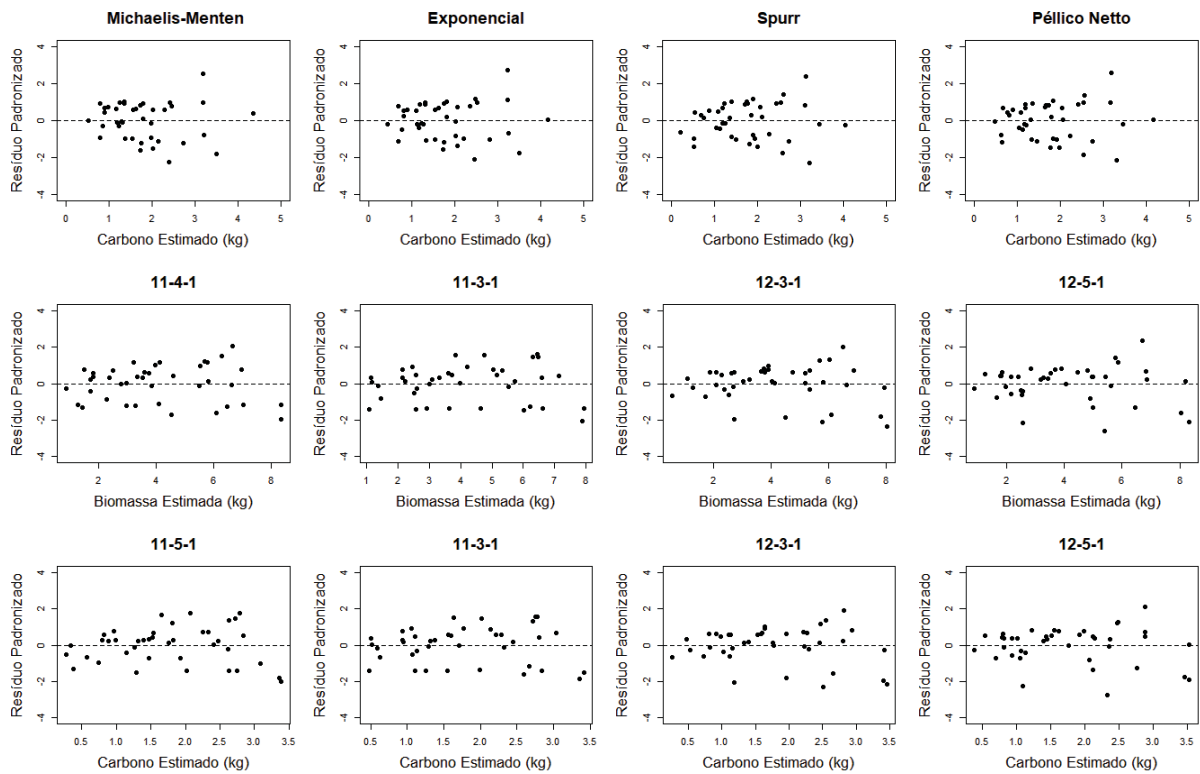
FIGURA 31 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

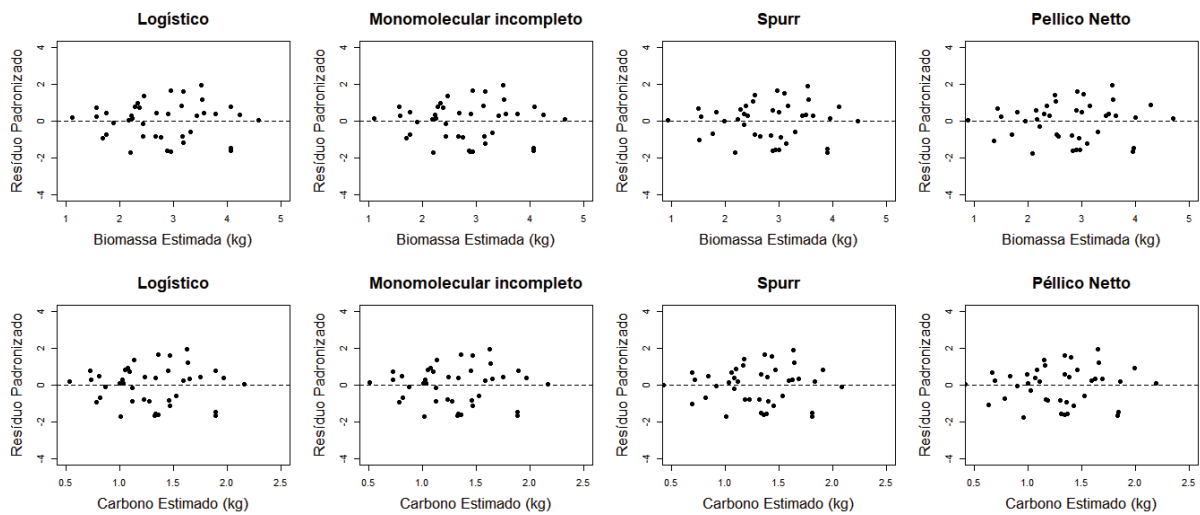
FIGURA 32 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

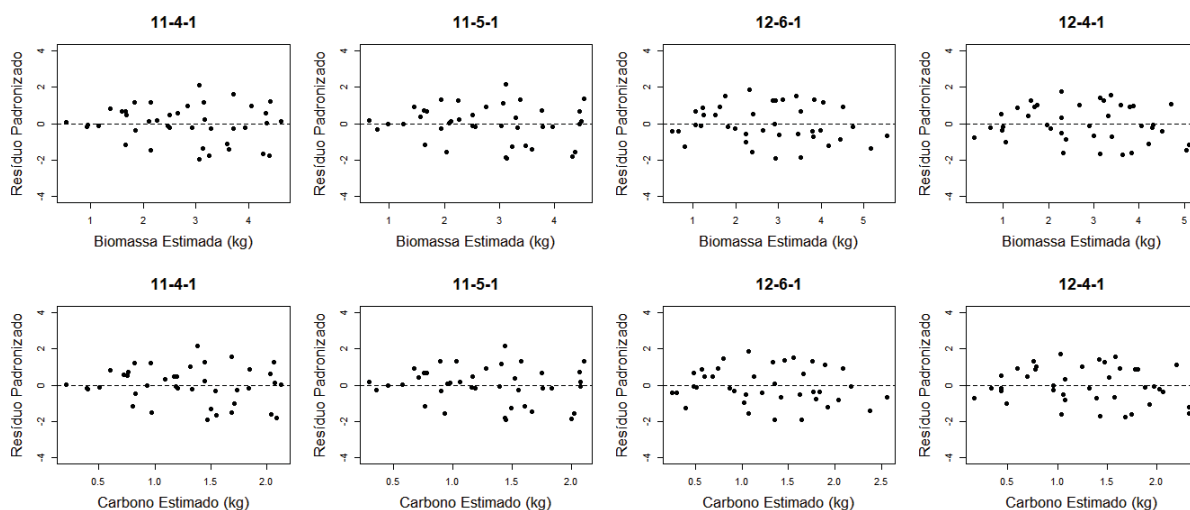




FONTE: O autor (2019).

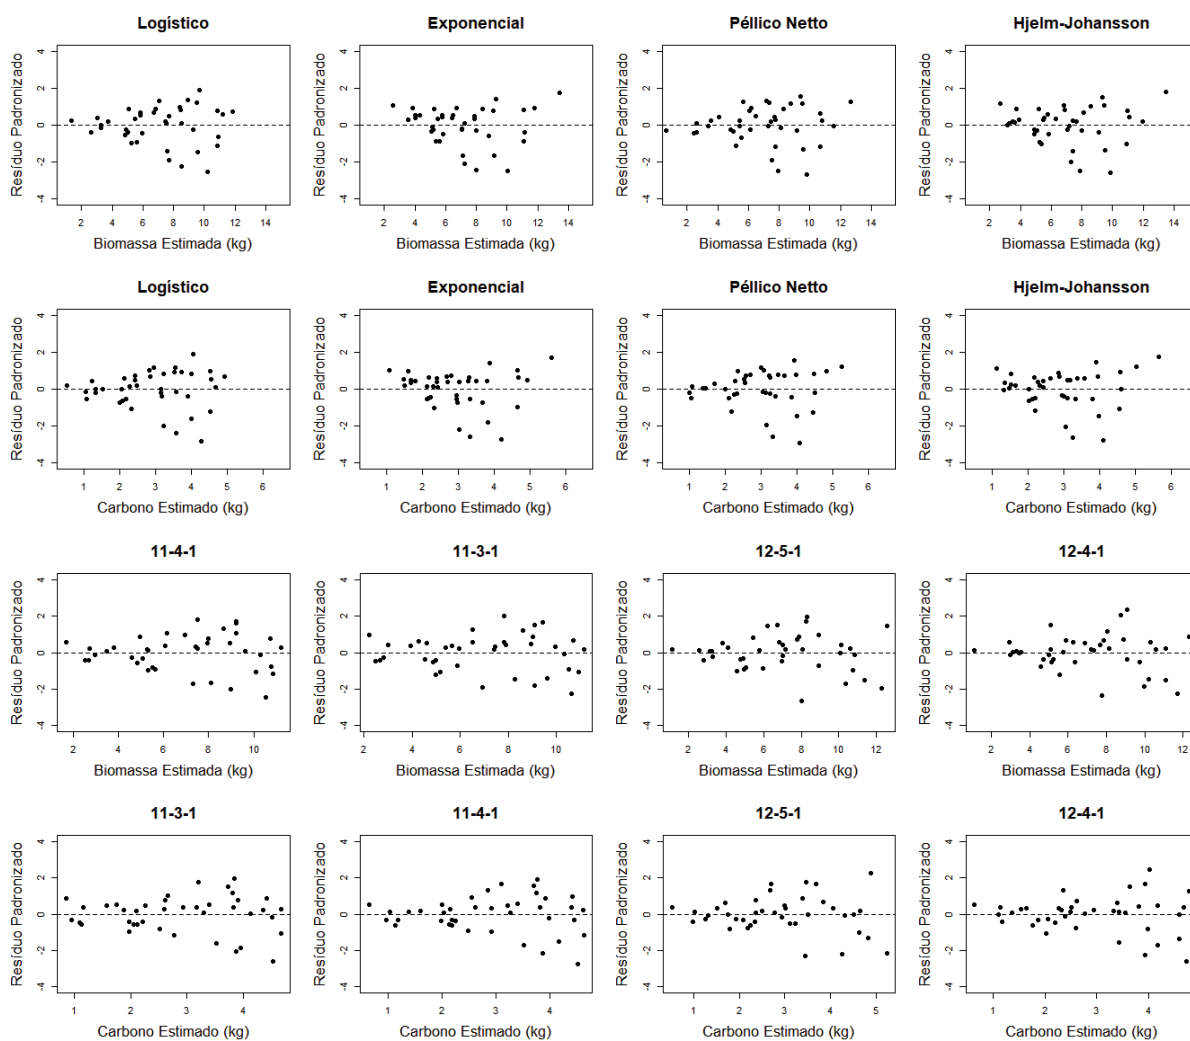
FIGURA 33 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA





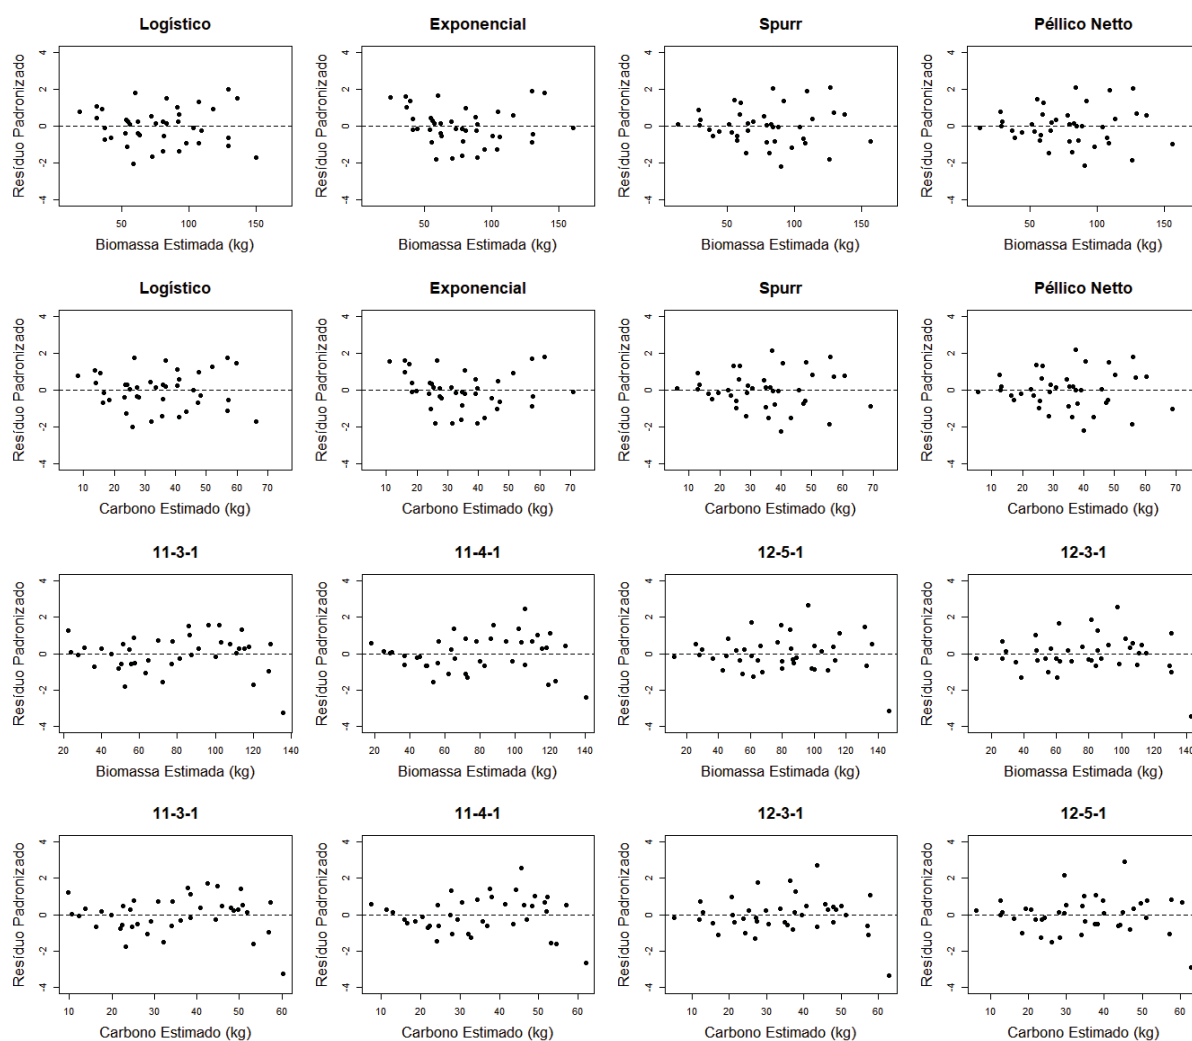
FONTE: O autor (2019).

FIGURA 34 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA




FONTE: O autor (2019).

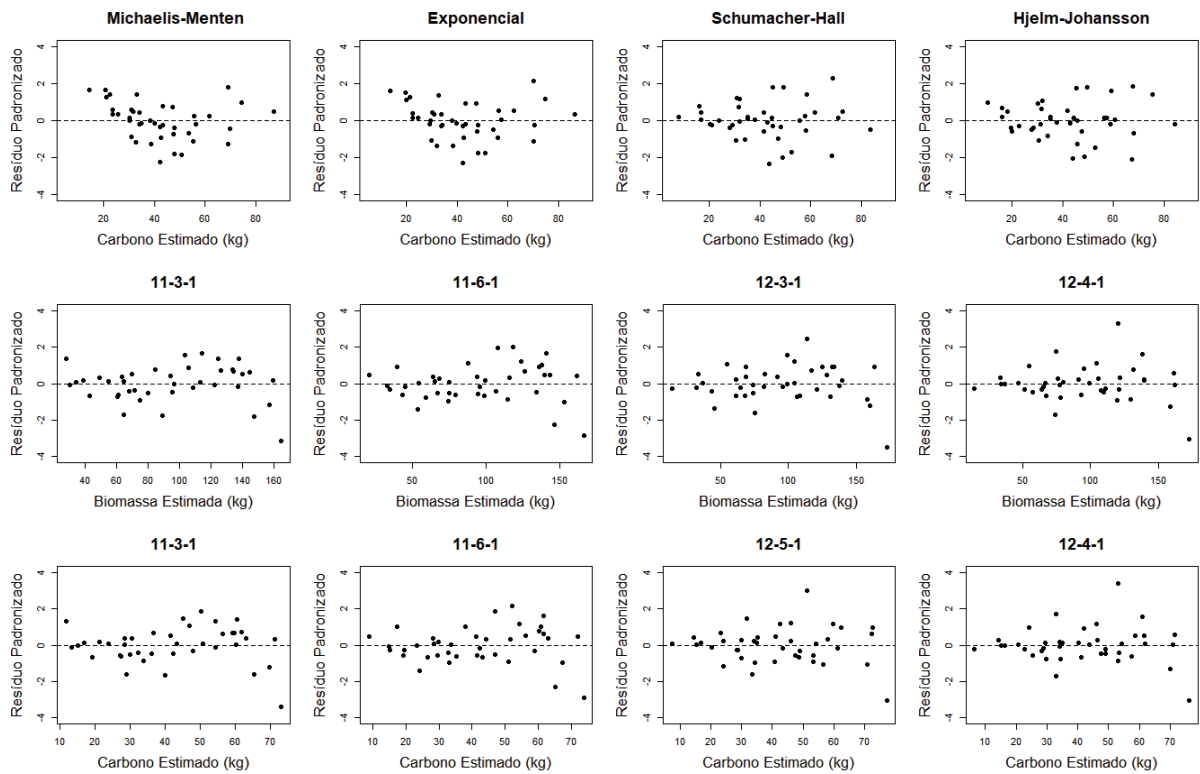
FIGURA 35 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

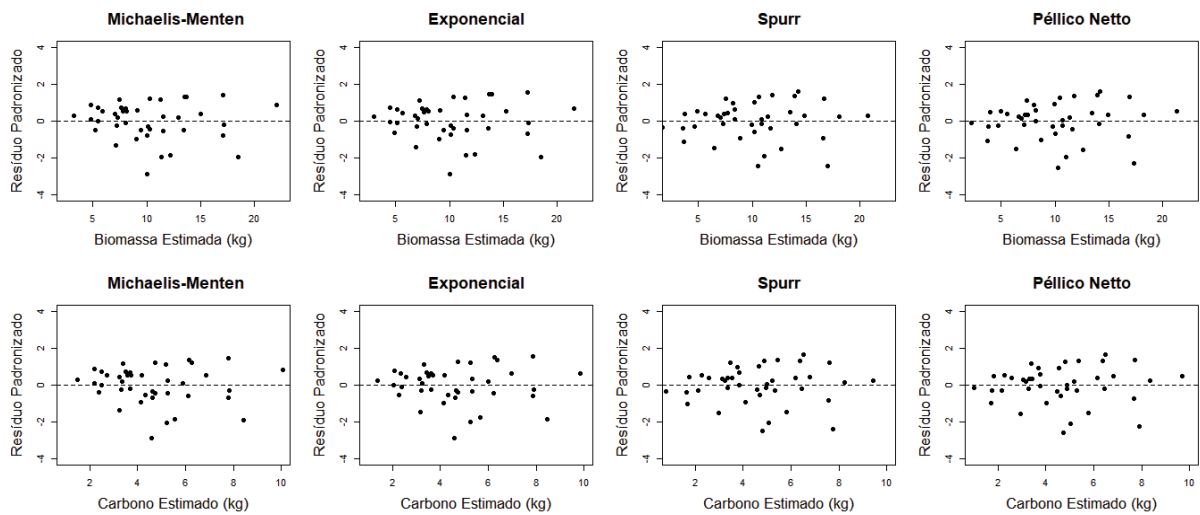
FIGURA 36 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

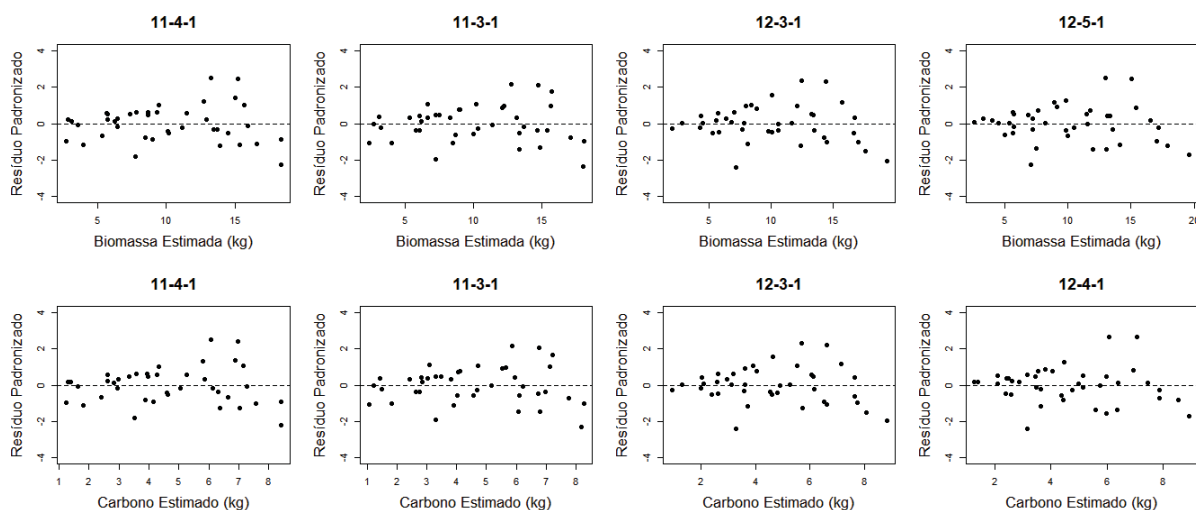




FONTE: O autor (2019).

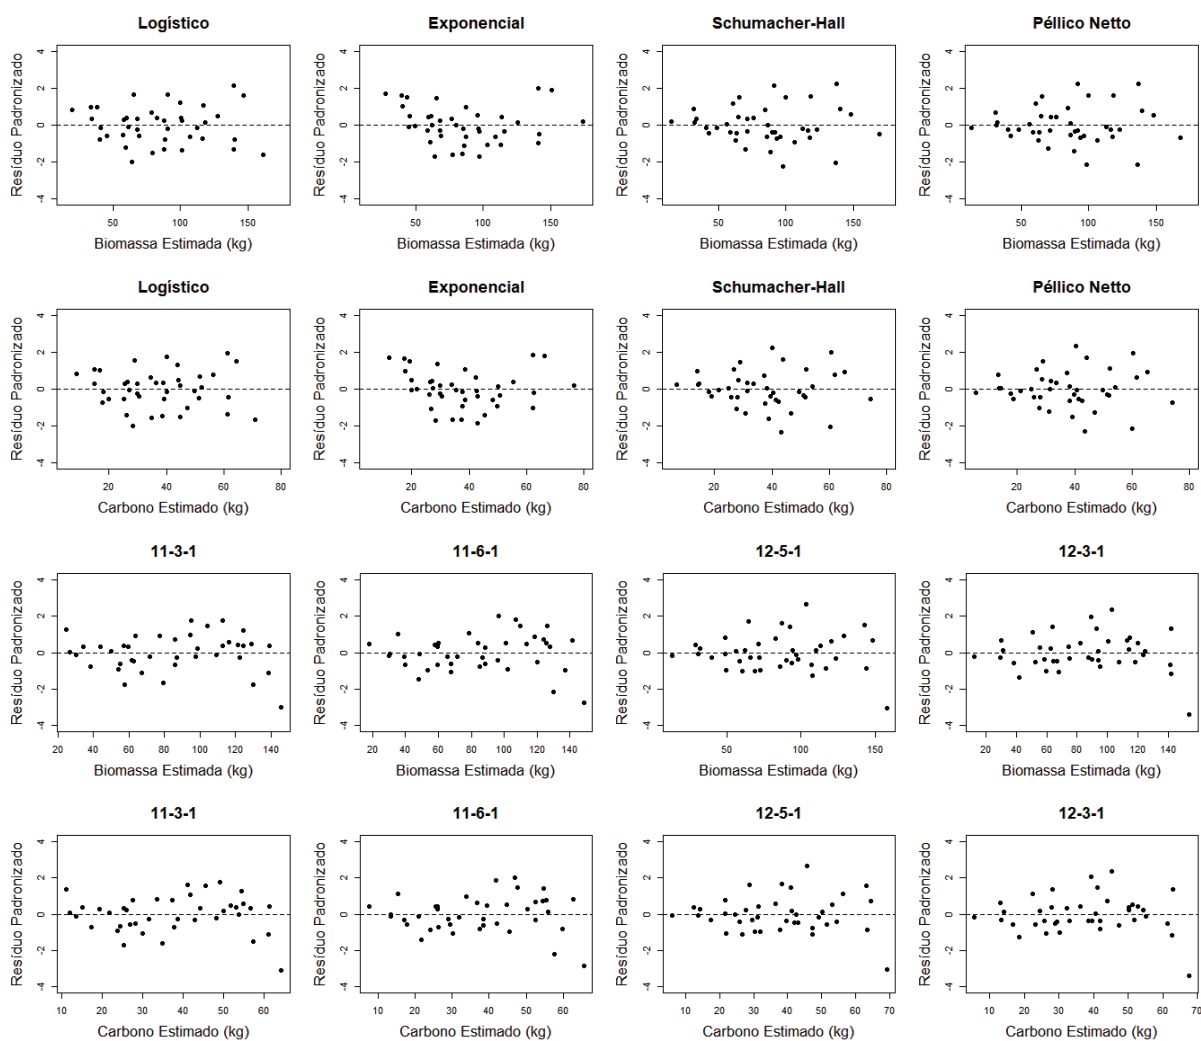
FIGURA 37 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA





FONTE: O autor (2019).

FIGURA 38 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE AJUSTE/TREINAMENTO COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

APÊNDICE 6 – QUALIDADE DAS ESTIMATIVAS PARA O CONJUNTO DE TESTE DAS DEMAIS EQUAÇÕES

TABELA 94 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		χ^2	pvalue
Biomassa	Regressão não linear	Monomolecular incompleto	0,861107	27,27	0,8232	4,3616	0,9998
		Michaelis-Menten	0,896184	28,39	0,8117	4,8790	0,9995
		Exponencial	0,870850	27,58	0,8191	4,4868	0,9997
		Spurr	0,930172	29,46	0,7888	4,9307	0,9995
		Péllico Netto	0,905173	28,67	0,8021	4,6511	0,9997
		Hjelm-Johansson	0,910334	28,83	0,7996	4,6305	0,9997
	Rede neural artificial	11-5-1	0,729062	23,09	0,8794	3,2394	1,0000
		11-3-1	0,777293	24,62	0,8617	3,3909	1,0000
		11-4-1	0,840765	26,63	0,8389	3,8086	0,9999
		12-5-1	0,868420	27,51	0,8264	4,4884	0,9997
		12-3-1	0,874379	27,69	0,8223	4,5401	0,9997
		12-4-1	0,937369	29,69	0,7941	5,2000	0,9992
Carbono	Regressão não linear	Monomolecular incompleto	0,436922	28,05	0,8232	2,3061	1,0000
		Michaelis-Menten	0,455362	29,23	0,8126	2,5816	1,0000
		Exponencial	0,441899	28,37	0,8191	2,3725	1,0000
		Spurr	0,469182	30,12	0,7891	2,5771	1,0000
		Péllico Netto	0,455557	29,25	0,8030	2,4217	1,0000
		Hjelm-Johansson	0,464204	29,80	0,7949	2,4769	1,0000
	Rede neural artificial	11-5-1	0,351777	22,58	0,8887	1,5435	1,0000
		11-3-1	0,392378	25,19	0,8601	1,7696	1,0000
		11-4-1	0,412012	26,45	0,8457	1,8631	1,0000
		12-5-1	0,420500	27,00	0,8382	2,1576	1,0000
		12-3-1	0,421266	27,05	0,8367	2,1502	1,0000
		12-4-1	0,456779	29,33	0,8057	2,5112	1,0000

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, χ^2 é o valor calculado do teste Qui-quadrado, e pvalue é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 95 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}y}$	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Monomolecular incompleto	1,177706	27,87	0,8161	6,3087	0,9971
		Michaelis-Menten	1,201825	28,45	0,8111	6,5094	0,9964
		Exponencial	1,181094	27,95	0,8153	6,3306	0,9970
		Spurr	1,346129	31,86	0,7542	8,8581	0,9758
		Péllico Netto	1,315096	31,13	0,7667	8,1972	0,9846
		Hjelm-Johansson	1,188553	28,13	0,8119	6,4356	0,9967
	Rede neural artificial	11-5-1	1,181292	27,96	0,8143	6,8533	0,9950
		11-4-1	1,201889	28,45	0,8084	6,7831	0,9953
		11-3-1	1,315619	31,14	0,7653	8,5985	0,9796
		12-3-1	1,306929	30,93	0,7698	8,8042	0,9766
		12-4-1	1,133845	26,84	0,8330	6,2954	0,9971
		12-5-1	1,228305	29,07	0,8012	7,8079	0,9885
Carbono	Regressão não linear	Monomolecular incompleto	0,512585	28,41	0,8081	2,8359	1,0000
		Michaelis-Menten	0,521757	28,92	0,8033	2,9088	1,0000
		Exponencial	0,513876	28,48	0,8073	2,8430	1,0000
		Spurr	0,577499	32,01	0,7523	3,8944	0,9999
		Péllico Netto	0,565182	31,33	0,7634	3,6027	1,0000
		Hjelm-Johansson	0,525403	29,12	0,7974	3,0001	1,0000
	Rede neural artificial	11-5-1	0,521238	28,89	0,8006	3,1047	1,0000
		11-4-1	0,516849	28,65	0,8060	2,9153	1,0000
		11-3-1	0,570831	31,64	0,7571	3,7772	0,9999
		12-3-1	0,551658	30,58	0,7757	3,6082	1,0000
		12-4-1	0,503765	27,92	0,8189	2,9585	1,0000
		12-5-1	0,539947	29,93	0,7889	3,5434	1,0000

REQM é a raiz do erro quadrático médio, $r_{\hat{y}y}$ é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 96 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Logístico	1,526466	72,67	0,2708	15,0263	0,7209
		Monomolecular incompleto	1,523935	72,55	0,2703	15,0155	0,7216
		Michaelis-Menten	1,521273	72,43	0,2697	14,9988	0,7227
		Spurr	1,546326	73,62	0,2255	15,4920	0,6909
		Schumacher-Hall	1,527894	72,74	0,3547	14,5254	0,7522
		Péllico Netto	1,555318	74,05	0,2016	15,6520	0,6804
	Rede neural artificial	11-3-1	1,302490	62,01	0,6104	10,8220	0,9297
		11-4-1	1,318350	62,77	0,5895	11,0781	0,9212
		11-5-1	1,308963	62,32	0,5894	11,0930	0,9207
		12-6-1	1,302778	62,03	0,6554	9,7448	0,9590
		12-4-1	1,284585	61,16	0,6613	9,6240	0,9616
		12-3-1	1,268470	60,39	0,6670	9,5599	0,9630
Carbono	Regressão não linear	Logístico	0,709153	72,65	0,2673	7,0104	0,9942
		Monomolecular incompleto	0,708957	72,63	0,2674	7,0129	0,9941
		Michaelis-Menten	0,707657	72,50	0,2667	7,0042	0,9942
		Spurr	0,719459	73,71	0,2228	7,2399	0,9928
		Schumacher-Hall	0,709792	72,72	0,3507	6,7754	0,9953
		Péllico Netto	0,723203	74,09	0,1992	7,3116	0,9924
	Rede neural artificial	11-6-1	0,603741	61,85	0,6156	4,8485	0,9995
		11-4-1	0,602881	61,76	0,6127	5,0140	0,9994
		11-5-1	0,604786	61,96	0,5946	5,1098	0,9993
		12-6-1	0,603416	61,82	0,6523	4,5191	0,9997
		12-4-1	0,587434	60,18	0,6640	4,3713	0,9998
		12-3-1	0,585639	60,00	0,6709	4,3981	0,9998

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 97 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}y}$	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Logístico	1,123711	17,31	0,9014	3,0482	1,0000
		Michaelis-Menten	1,085668	16,72	0,8779	3,3708	1,0000
		Exponencial	1,095974	16,88	0,8750	3,3301	1,0000
		Spurr	1,195853	18,42	0,8557	3,6932	0,9999
		Péllico Netto	1,223902	18,85	0,8596	3,7644	0,9999
		Hjelm-Johansson	1,213701	18,70	0,8501	3,8345	0,9999
	Rede neural artificial	11-6-1	1,026284	15,81	0,9316	2,5117	1,0000
		11-4-1	1,071793	16,51	0,9159	2,9283	1,0000
		11-3-1	1,086151	16,73	0,9095	3,1698	1,0000
		12-6-1	0,834319	12,85	0,9702	1,5435	1,0000
		12-5-1	0,838855	12,92	0,9703	1,4557	1,0000
		12-4-1	0,883096	13,60	0,9560	1,6536	1,0000
Carbono	Regressão não linear	Logístico	0,513579	19,28	0,8909	1,4979	1,0000
		Michaelis-Menten	0,492110	18,48	0,8649	1,6753	1,0000
		Exponencial	0,495892	18,62	0,8615	1,6458	1,0000
		Spurr	0,538157	20,20	0,8405	1,7739	1,0000
		Péllico Netto	0,549525	20,63	0,8470	1,7658	1,0000
		Hjelm-Johansson	0,557896	20,95	0,8237	1,9211	1,0000
	Rede neural artificial	11-6-1	0,432681	16,24	0,9400	1,0731	1,0000
		11-3-1	0,452965	17,01	0,9259	1,2933	1,0000
		11-4-1	0,452240	16,98	0,9278	1,2334	1,0000
		12-5-1	0,396867	14,90	0,9627	0,8055	1,0000
		12-3-1	0,383996	14,42	0,9586	0,8492	1,0000
		12-4-1	0,445888	16,74	0,9304	1,0472	1,0000

REQM é a raiz do erro quadrático médio, $r_{\hat{y}y}$ é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 98 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Logístico	9,374787	12,81	0,9488	19,2093	0,4435
		Michaelis-Menten	8,867737	12,12	0,9442	21,1288	0,3297
		Exponencial	8,972995	12,26	0,9439	20,1808	0,3838
		Spurr	6,192966	8,46	0,9808	8,9239	0,9747
		Schumacher-Hall	6,053670	8,27	0,9820	8,5547	0,9802
		Péllico Netto	6,255884	8,55	0,9809	9,1369	0,9711
	Rede neural artificial	11-3-1	9,403560	12,85	0,9580	18,2416	0,5064
		11-6-1	9,221970	12,60	0,9621	16,2767	0,6387
		11-4-1	9,937587	13,58	0,9572	20,3112	0,3761
		12-5-1	7,198800	9,84	0,9767	11,3118	0,9129
		12-3-1	7,283808	9,96	0,9751	12,7900	0,8491
		12-4-1	7,193677	9,83	0,9769	11,1799	0,9176
Carbono	Regressão não linear	Logístico	4,095297	12,61	0,9489	8,4175	0,9820
		Michaelis-Menten	3,928020	12,10	0,9438	9,5348	0,9635
		Exponencial	3,958869	12,19	0,9436	9,0691	0,9723
		Spurr	2,762721	8,51	0,9790	4,0495	0,9999
		Schumacher-Hall	2,719750	8,38	0,9798	3,9313	0,9999
		Péllico Netto	2,781261	8,56	0,9792	4,1032	0,9999
	Rede neural artificial	11-3-1	4,085040	12,58	0,9590	7,7460	0,9890
		11-6-1	4,011042	12,35	0,9616	6,9399	0,9945
		11-4-1	4,039615	12,44	0,9624	7,4518	0,9914
		12-3-1	3,327256	10,25	0,9714	5,8776	0,9982
		12-4-1	3,185520	9,81	0,9751	4,8974	0,9995
		12-5-1	3,706063	11,41	0,9640	6,7332	0,9955

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 99 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}y}$	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Logístico	9,819996	11,02	0,9676	17,5423	0,5532
		Monomolecular incompleto	9,285488	10,42	0,9637	17,8701	0,5311
		Exponencial	9,359304	10,50	0,9610	18,8918	0,4638
		Schumacher-Hall	7,653525	8,59	0,9815	11,0800	0,9211
		Péllico Netto	7,526157	8,44	0,9829	10,7121	0,9331
		Hjelm-Johansson	7,680786	8,62	0,9825	10,5973	0,9366
	Rede neural artificial	11-3-1	10,244931	11,49	0,9725	17,4791	0,5574
		11-6-1	10,654226	11,95	0,9708	17,8819	0,5303
		11-4-1	10,219283	11,46	0,9764	16,7219	0,6087
		12-3-1	8,915026	10,00	0,9775	15,4331	0,6947
		12-5-1	8,907420	9,99	0,9771	14,1363	0,7757
		12-4-1	9,062054	10,17	0,9768	14,4294	0,7581
Carbono	Regressão não linear	Monomolecular incompleto	4,183703	10,60	0,9613	8,4264	0,9818
		Michaelis-Menten	4,201241	10,64	0,9583	9,5799	0,9626
		Exponencial	4,226771	10,71	0,9585	8,9363	0,9745
		Schumacher-Hall	3,510582	8,89	0,9781	5,3713	0,9990
		Péllico Netto	3,459581	8,76	0,9794	5,1729	0,9993
		Hjelm-Johansson	3,542934	8,98	0,9782	5,1738	0,9993
	Rede neural artificial	11-5-1	4,267126	10,81	0,9770	6,4052	0,9968
		11-3-1	4,353311	11,03	0,9756	6,9350	0,9946
		11-6-1	4,513046	11,43	0,9725	7,1678	0,9933
		12-3-1	3,906975	9,90	0,9760	6,5815	0,9961
		12-5-1	3,978282	10,08	0,9750	6,3107	0,9971
		12-4-1	4,020520	10,19	0,9752	6,3686	0,9969

REQM é a raiz do erro quadrático médio, $r_{\hat{y}y}$ é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

TABELA 100 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		r_{yy}	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Monomolecular incompleto	2,181528	23,01	0,8368	8,2399	0,9841
		Michaelis-Menten	2,208328	23,29	0,8301	8,6856	0,9783
		Exponencial	2,189965	23,09	0,8343	8,3372	0,9829
		Spurr	2,557819	26,97	0,7734	11,4128	0,9092
		Péllico Netto	2,540422	26,79	0,7756	11,0841	0,9210
		Hjelm-Johansson	2,235051	23,57	0,8315	8,3765	0,9825
	Rede neural artificial	11-6-1	2,040369	21,52	0,8761	7,9840	0,9868
		11-4-1	2,208365	23,29	0,8539	8,4774	0,9812
		11-3-1	2,201619	23,22	0,8510	8,7306	0,9777
		12-3-1	2,166770	22,85	0,8554	9,2620	0,9689
		12-5-1	2,171759	22,90	0,8558	9,0521	0,9726
		12-4-1	2,161849	22,80	0,8556	8,5830	0,9798
Carbono	Regressão não linear	Monomolecular incompleto	0,999070	23,03	0,8367	3,8531	0,9999
		Michaelis-Menten	1,012539	23,34	0,8300	4,0677	0,9999
		Exponencial	1,003385	23,13	0,8341	3,9027	0,9999
		Spurr	1,161989	26,79	0,7768	5,2370	0,9992
		Péllico Netto	1,154942	26,62	0,7788	5,1016	0,9993
		Hjelm-Johansson	1,046641	24,13	0,8220	4,0690	0,9999
	Rede neural artificial	11-6-1	0,924251	21,31	0,8783	3,5727	1,0000
		11-4-1	0,997260	22,99	0,8576	3,7666	0,9999
		11-3-1	0,998774	23,02	0,8528	3,9063	0,9999
		12-3-1	0,987550	22,77	0,8566	4,1914	0,9998
		12-5-1	0,983103	22,66	0,8573	4,0845	0,9999
		12-4-1	0,988260	22,78	0,8566	3,9203	0,9999

REQM é a raiz do erro quadrático médio, r_{yy} é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

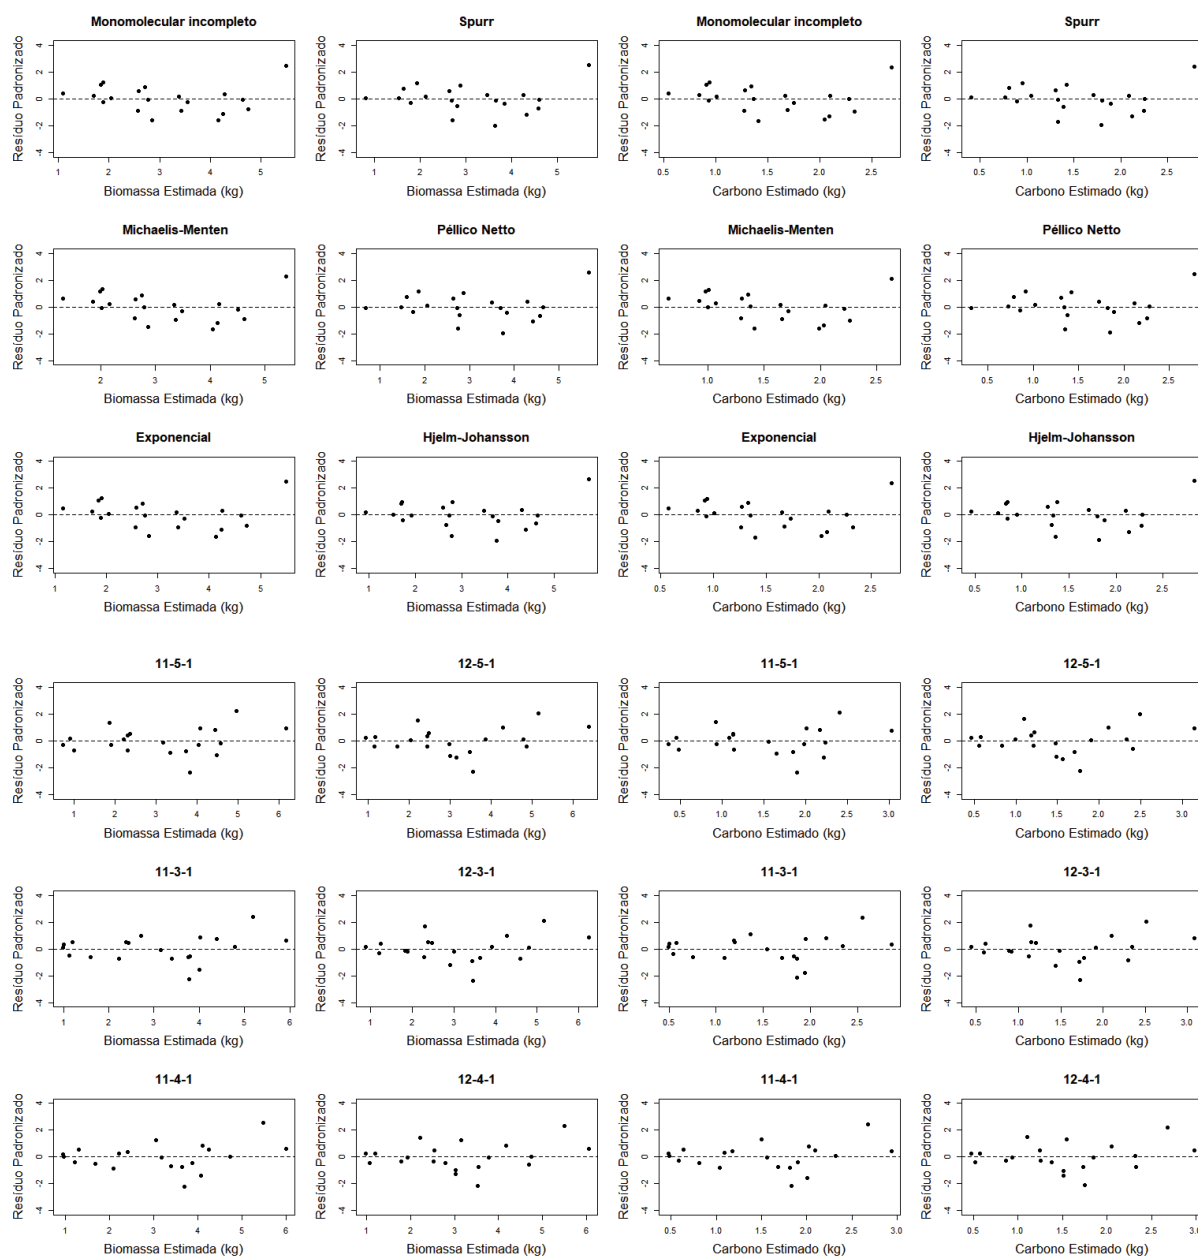
TABELA 101 – QUALIDADE DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA

Variável	Método	Modelo/Arquitetura	REQM		$r_{\hat{y}y}$	Qui-Quadrado	
			kg	(%)		X^2	p _{value}
Biomassa	Regressão não linear	Logístico	9,732226	12,22	0,9562	18,6265	0,4810
		Michaelis-Menten	9,125103	11,46	0,9504	20,7860	0,3487
		Exponencial	9,242290	11,60	0,9501	19,7562	0,4094
		Spurr	6,583861	8,27	0,9829	8,9645	0,9741
		Schumacher-Hall	6,623320	8,32	0,9826	9,0690	0,9723
		Péllico Netto	6,645848	8,34	0,9834	9,1665	0,9706
	Rede neural artificial	11-3-1	10,400332	13,06	0,9576	20,9788	0,3380
		11-6-1	10,276108	12,90	0,9606	18,7712	0,4716
		11-4-1	9,681125	12,15	0,9690	17,2057	0,5759
		12-5-1	7,873207	9,88	0,9776	12,1932	0,8772
		12-3-1	7,825819	9,82	0,9766	13,3016	0,8228
		12-4-1	7,821872	9,82	0,9783	11,9762	0,8866
Carbono	Regressão não linear	Logístico	4,288447	12,21	0,9551	8,4001	0,9822
		Michaelis-Menten	4,077879	11,61	0,9488	9,6500	0,9611
		Exponencial	4,113863	11,71	0,9485	9,1451	0,9710
		Spurr	2,995220	8,52	0,9800	4,2869	0,9998
		Schumacher-Hall	3,030140	8,62	0,9793	4,3881	0,9998
		Péllico Netto	3,014005	8,58	0,9807	4,3233	0,9998
	Rede neural artificial	11-3-1	4,390145	12,49	0,9608	8,4962	0,9809
		11-6-1	4,338565	12,35	0,9634	7,5319	0,9908
		11-4-1	4,209041	11,98	0,9689	7,3618	0,9920
		12-5-1	3,495575	9,95	0,9756	5,3679	0,9991
		12-3-1	3,472051	9,88	0,9751	5,7697	0,9984
		12-4-1	3,425738	9,75	0,9773	5,1402	0,9993

REQM é a raiz do erro quadrático médio, $r_{\hat{y}y}$ é o coeficiente de correlação linear de Pearson, X^2 é o valor calculado do teste Qui-quadrado, e p_{value} é a significância do teste Qui-quadrado. FONTE: O autor (2019).

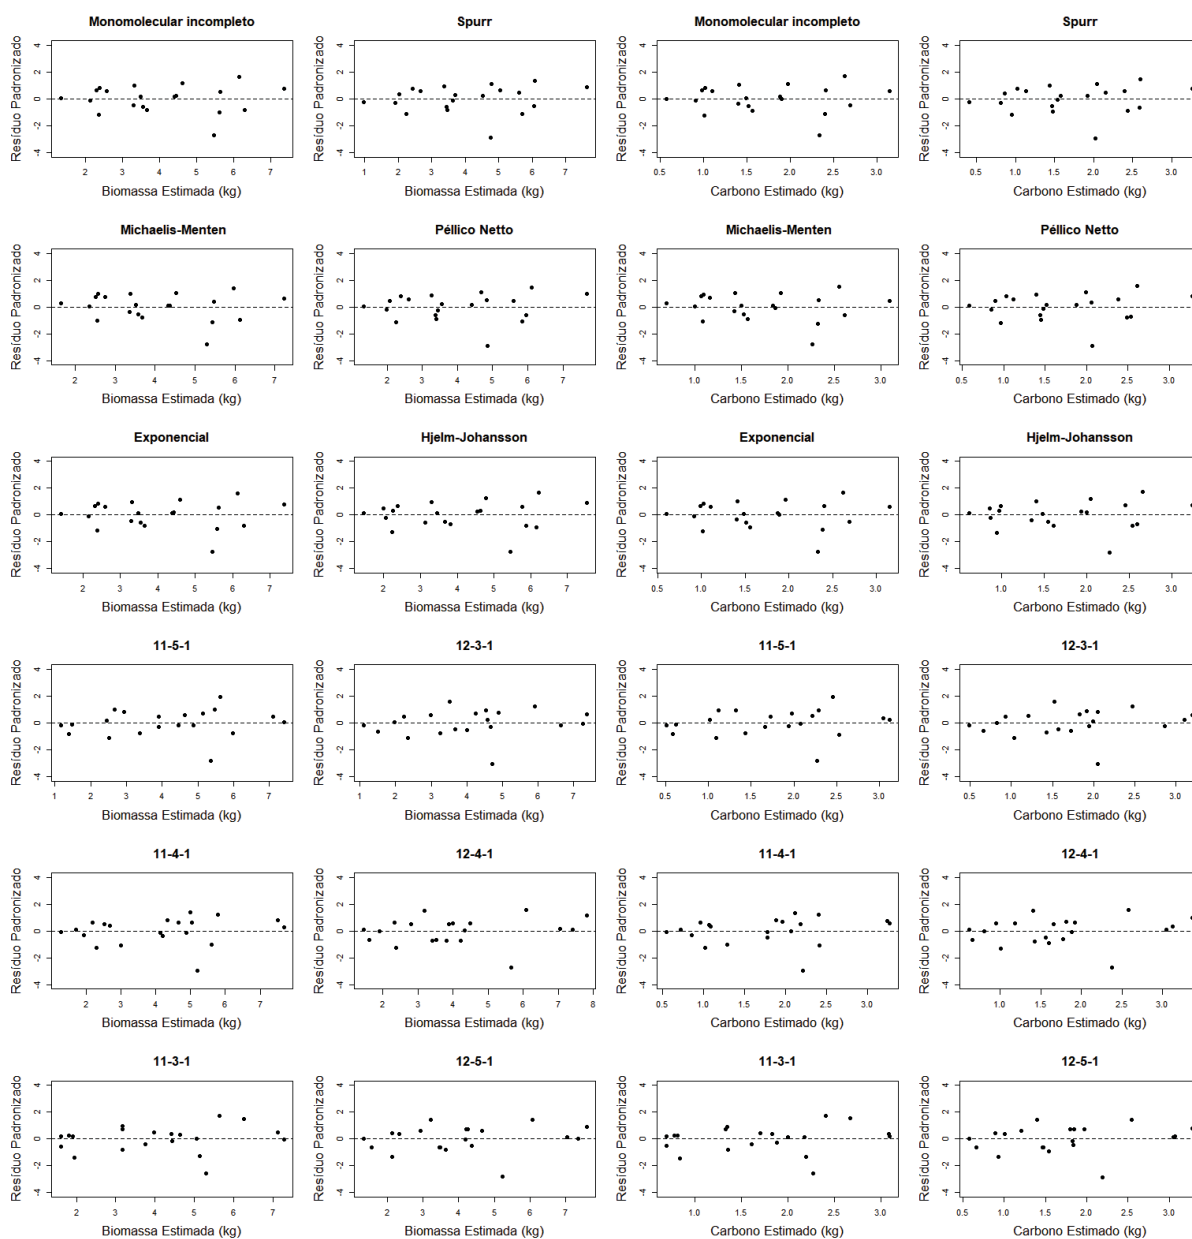
APÊNDICE 7 – GRÁFICOS DE RESÍDUOS PARA O CONJUNTO DE TESTE DAS DEMAIS EQUAÇÕES

FIGURA 39 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



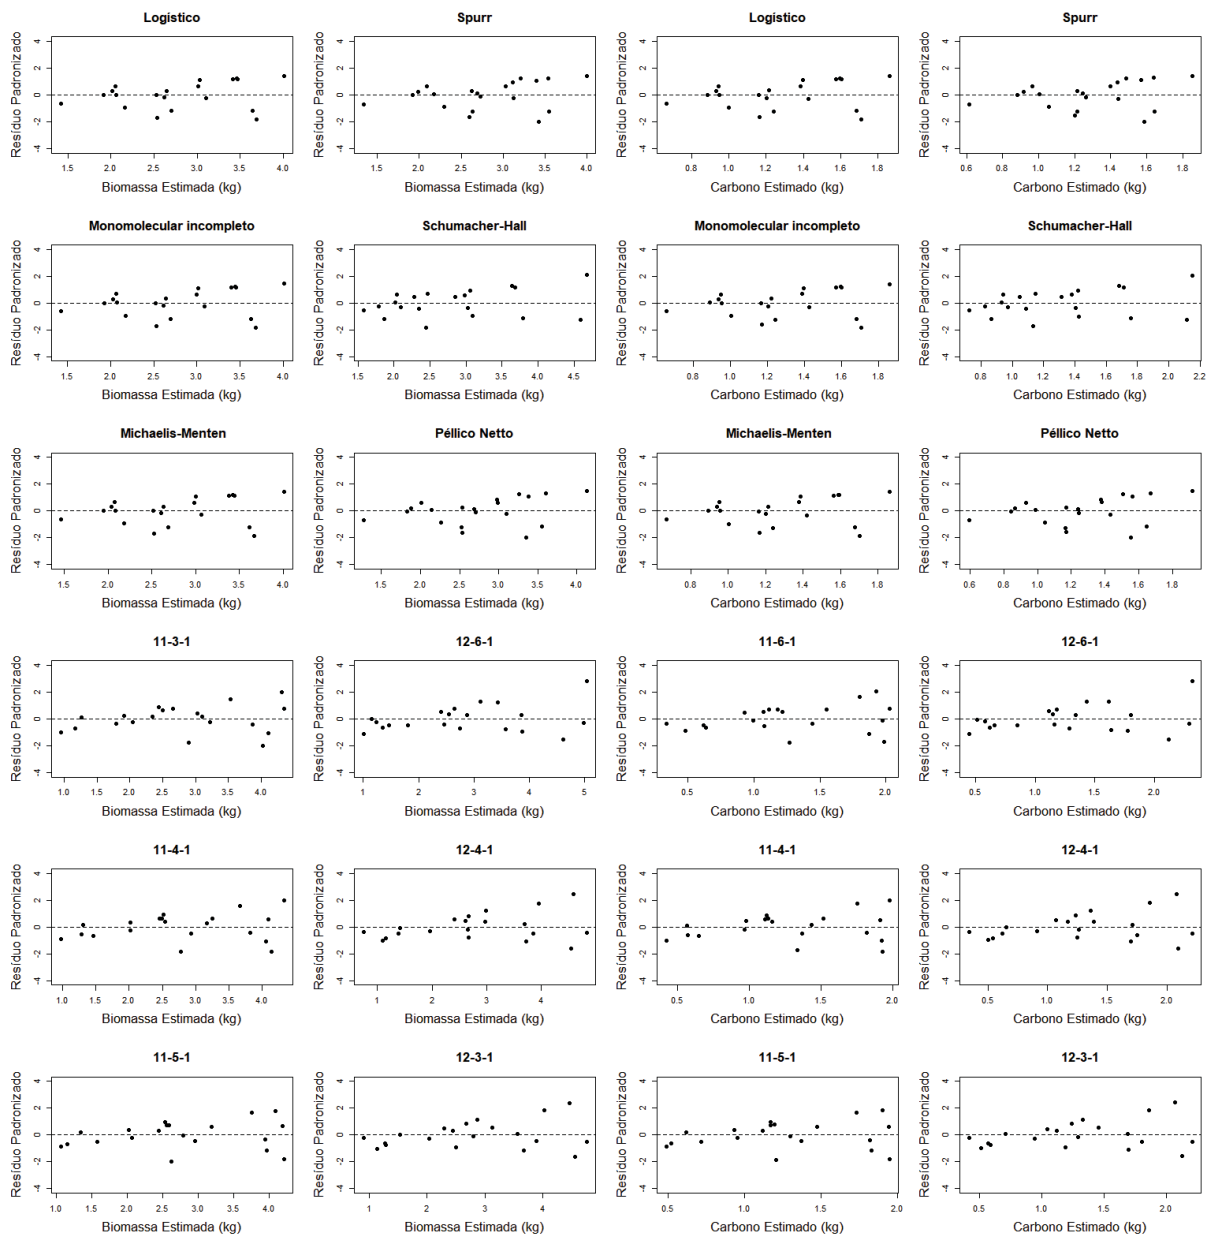
FONTE: O autor (2019).

FIGURA 40 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



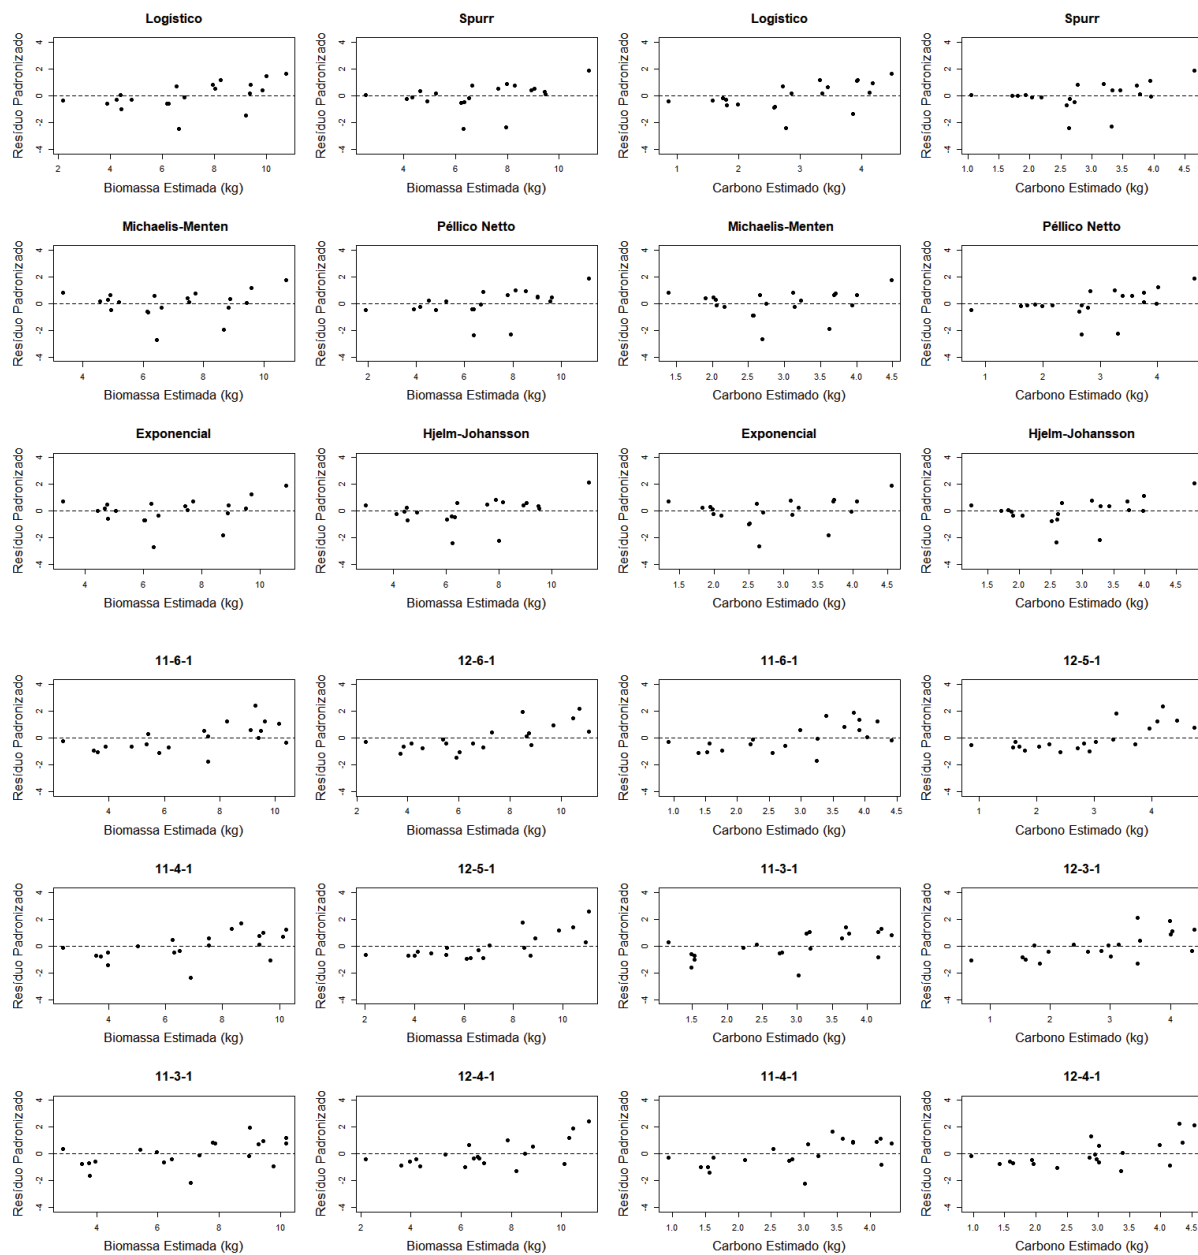
FONTE: O autor (2019).

FIGURA 41 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS SECOS DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



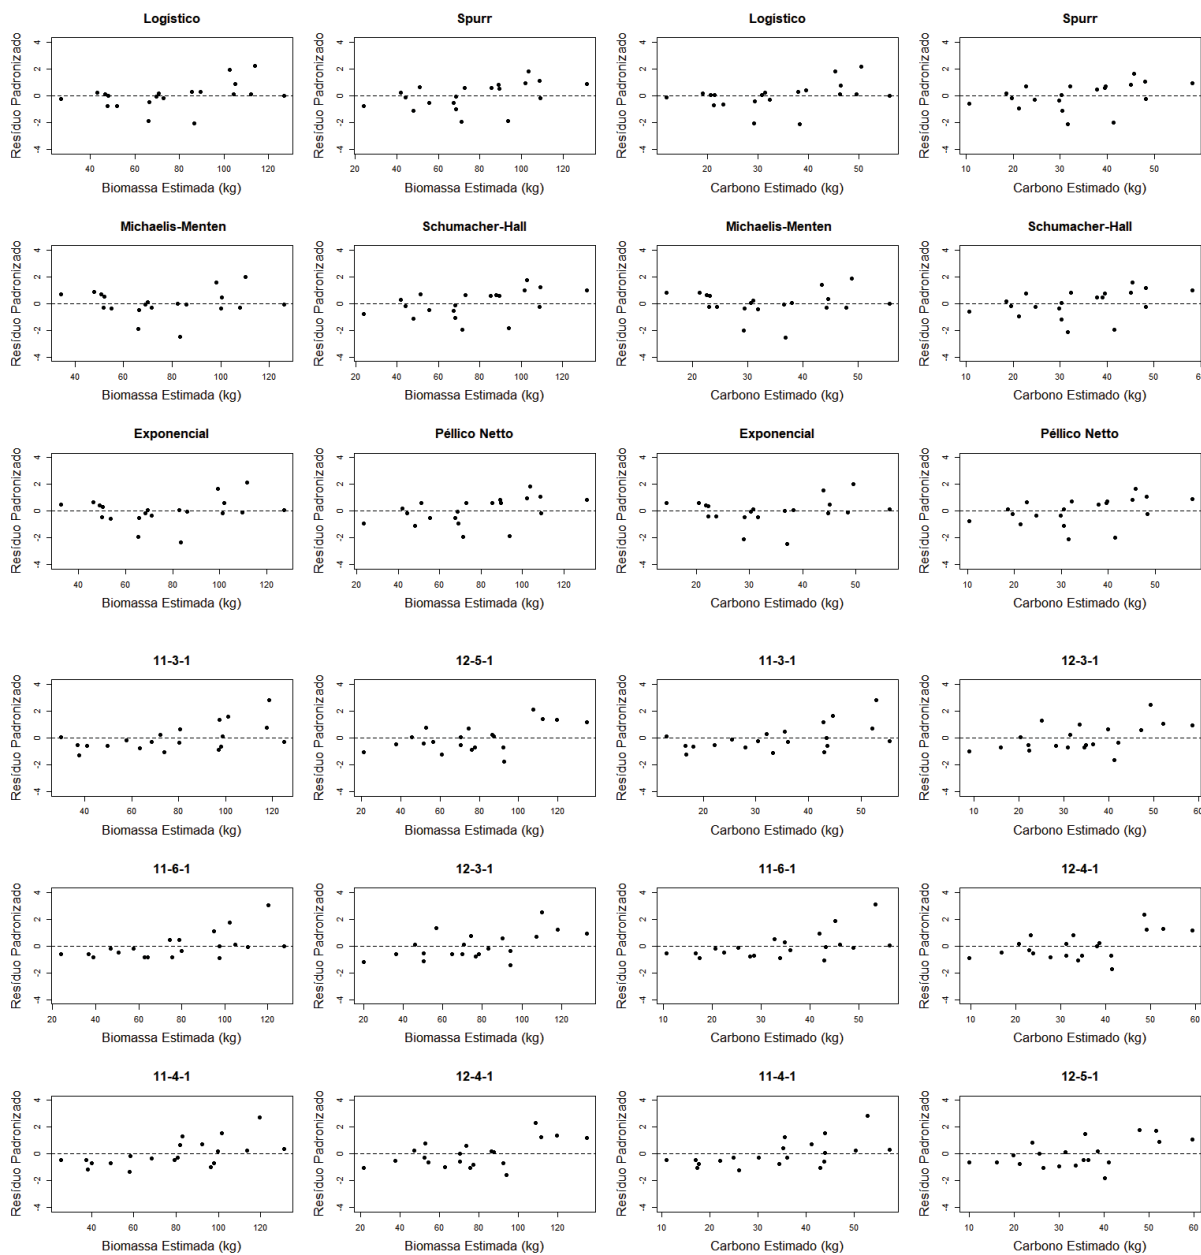
FONTE: O autor (2019).

FIGURA 42 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE CASCA DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



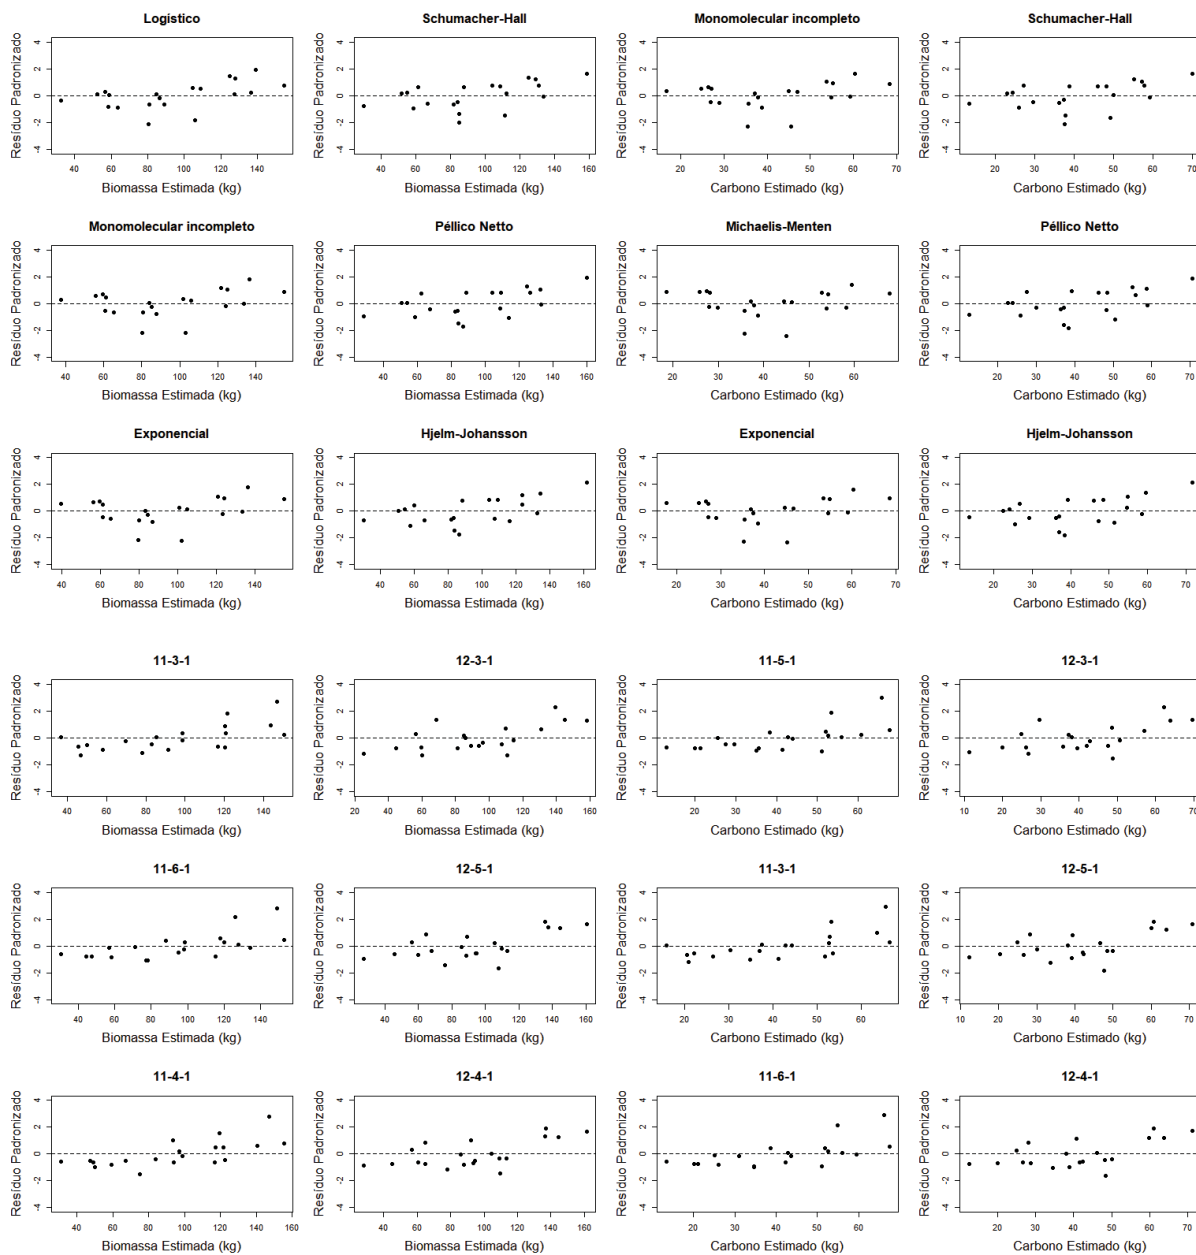
FONTE: O autor (2019).

FIGURA 43 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE LENHO DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



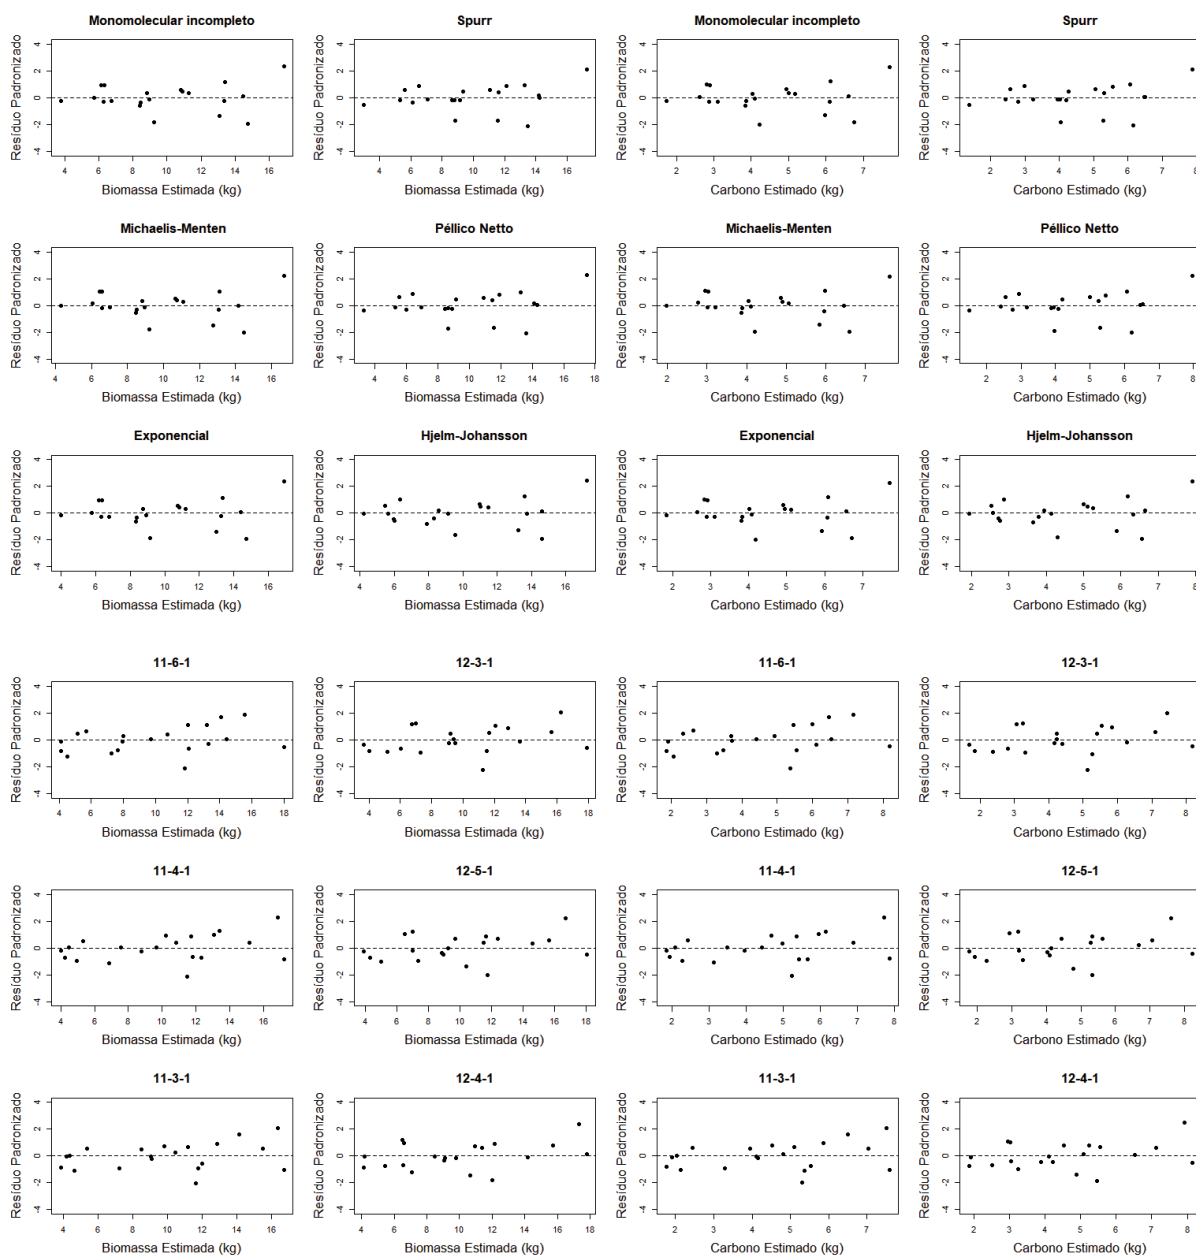
FONTE: O autor (2019).

FIGURA 44 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO TOTAL DOS COMPONENTES DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



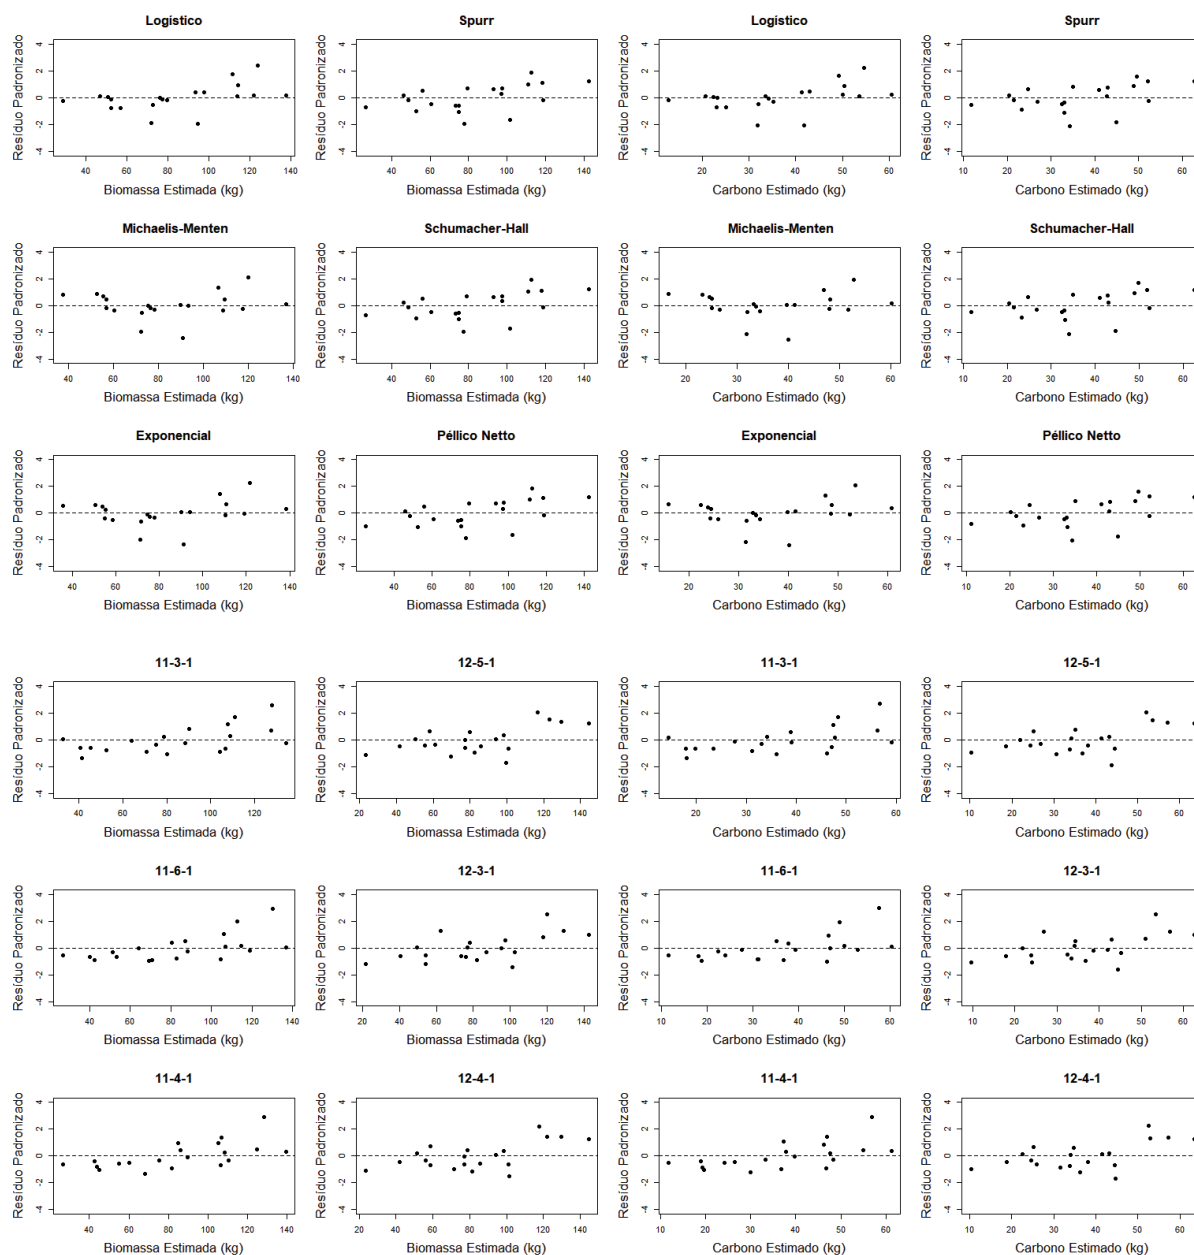
FONTE: O autor (2019).

FIGURA 45 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

FIGURA 46 – DISTRIBUIÇÃO RESIDUAL DAS ESTIMATIVAS DA BIOMASSA SECA E DO CARBONO ORGÂNICO ESTOCADO NO COMPONENTE TRONCO DO CONJUNTO DE TESTE COM AS DEMAIS EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR RNA



FONTE: O autor (2019).

APÊNDICE 8 – EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR E POR REDE NEURAL ARTIFICIAL

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR A BIOMASSA SECA DO COMPONENTE FOLHAS

$$\begin{aligned}
 \phi_1 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,633556 + C_1 \cdot 0,215482 + C_2 \cdot 0,347005 + C_3 \cdot 0,097672 + C_4 \cdot 0,500805 + C_5 \cdot 0,391935 + C_6 \cdot 0,707744 + C_7 \cdot 0,454051 + C_8 \cdot 0,271213 + C_9 \cdot 0,341231 + C_{10} \cdot 0,232569 + 0,1818943094 \right]}} - 1 \\
 \phi_2 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,677865 + C_1 \cdot 0,186245 + C_2 \cdot 0,457026 + C_3 \cdot 0,135328 + C_4 \cdot 0,022331 + C_5 \cdot 0,321151 + C_6 \cdot 0,058502 + C_7 \cdot 0,562659 + C_8 \cdot 0,144912 + C_9 \cdot 0,116173 + C_{10} \cdot 0,399618 + 0,2130178893 \right]}} - 1 \\
 \phi_3 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,382015 + C_1 \cdot 0,015437 + C_2 \cdot 0,035421 + C_3 \cdot 0,502454 + C_4 \cdot 0,021729 + C_5 \cdot 0,098568 + C_6 \cdot 0,232430 + C_7 \cdot 0,259401 + C_8 \cdot 0,080546 + C_9 \cdot 0,353676 + C_{10} \cdot 0,051799 - 0,0600760913 \right]}} - 1 \\
 \phi_4 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,200165 + C_1 \cdot 0,473141 + C_2 \cdot 0,497319 + C_3 \cdot 0,504046 + C_4 \cdot 0,509422 + C_5 \cdot 0,489344 + C_6 \cdot 0,277337 + C_7 \cdot 0,488712 + C_8 \cdot 0,366811 + C_9 \cdot 0,647877 + C_{10} \cdot 0,217774 + 0,0839358134 \right]}} - 1 \\
 \phi_5 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) \cdot 0,296878 + C_1 \cdot 0,491133 + C_2 \cdot 0,401531 + C_3 \cdot 0,410963 + C_4 \cdot 0,552551 + C_5 \cdot 0,109271 + C_6 \cdot 0,021502 + C_7 \cdot 0,166019 + C_8 \cdot 0,208338 + C_9 \cdot 0,407648 + C_{10} \cdot 0,598835 - 0,0365726546 \right]}} - 1 \\
 \phi_6 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) \cdot 0,333146 + C_1 \cdot 0,539680 + C_2 \cdot 0,537415 + C_3 \cdot 0,148190 + C_4 \cdot 0,097791 + C_5 \cdot 0,394975 + C_6 \cdot 0,097623 + C_7 \cdot 0,168735 + C_8 \cdot 0,306898 + C_9 \cdot 0,210935 + C_{10} \cdot 0,220784 - 0,0138225526 \right]}} - 1
 \end{aligned}$$

$$\text{ms}_{\text{folhas}} = 1,845678898 (\phi_1 - 0,8842791915 + \phi_2 - 0,69011116 + \phi_3 - 0,54141057 + \phi_4 - 0,472021103 + \phi_5 - 0,707382441 + \phi_6 - 0,518779099 + 0,03105916958) + 3,165849142$$

Sendo, $\phi_{1,2,3,4,5,6}$ as saídas dos neurônios 1, 2, 3, 4, 5 e 6, respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, e $C_{1,2,3,4,5,6,7,8,9,10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR A BIOMASSA SECA DO COMPONENTE GALHOS VIVOS

$$\begin{aligned} \phi_1 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,601947 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,069307 + C_1 - 0,178756 + C_2 - 0,357789 + C_3 - 0,185022 + C_4 - 0,393250 + C_5 - 0,336873 + C_6 - 0,046506 + C_7 - 0,485105 + C_8 - 0,046506 + C_9 - 0,342715 + C_{10} - 0,238377 + 0,25666747 \right]}} \\ \phi_2 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,151897 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,047881 + C_1 - 0,096341 + C_2 - 0,064586 + C_3 - 0,049295 + C_4 - 0,232160 + C_5 - 0,109527 + C_6 - 0,387782 + C_7 - 0,124148 + C_8 - 0,106194 + C_9 - 0,552969 + C_{10} - 0,504816 - 0,24048512 \right]}} \\ \phi_3 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,292948 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,222786 + C_1 - 0,619454 + C_2 - 0,056397 + C_3 - 0,192547 + C_4 - 0,365829 + C_5 - 0,287518 + C_6 - 0,094262 + C_7 - 0,532410 + C_8 - 0,193293 + C_9 - 0,024658 + C_{10} - 0,182449 - 0,08929225 \right]}} \\ \phi_4 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,606969 + \left(\frac{h_t - 22,187}{2,594545265} \right) 0,238851 + C_1 - 0,396236 + C_2 - 0,283665 + C_3 - 0,107533 + C_4 - 0,479374 + C_5 - 0,469737 + C_6 - 0,674008 + C_7 - 0,327121 + C_8 - 0,568107 + C_9 - 0,438548 - 0,59782389 \right]}} \\ \phi_5 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,148089 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,423982 + C_1 - 0,038380 + C_2 - 0,042042 + C_3 - 0,154775 + C_4 - 0,214590 + C_5 - 0,542313 + C_6 - 0,449594 + C_7 - 0,265610 + C_8 - 0,053411 + C_9 - 0,446907 + C_{10} - 0,470040 - 0,10268836 \right]}} \\ \phi_6 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,659663 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,126578 + C_1 - 0,297965 + C_2 - 0,029487 + C_3 - 0,345824 + C_4 - 0,395566 + C_5 - 0,233866 + C_6 - 0,297922 + C_7 - 0,414376 + C_8 - 0,340435 + C_9 - 0,007574 + C_{10} - 0,065431 + 0,13293390 \right]}} \\ ms_{\text{galhos vivos}} &= 2,279156493 (\phi_1 - 0,7088992596 + \phi_2 - 0,4777275622 + \phi_3 - 0,7183693647 + \phi_4 - 0,6757565141 + \phi_5 - 0,4812954068 + \phi_6 - 0,7719947100 + 0,1080930959) + 4,160445454 \end{aligned}$$

Sendo, $\phi_{1,2,3,4,5,6}$ as saídas dos neurônios 1, 2, 3, 4, 5 e 6, respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, h_t a altura total, em m e $C_{1,2,3,4,5,6,7,8,9,10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR A BIOMASSA SECA DO COMPONENTE COPA

$$\begin{aligned}
 \phi_1 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,646247 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,238225 + C_1 - 0,208610 + C_2 - 0,280283 + C_3 - 0,269937 + C_4 - 0,488134 + C_5 - 0,365430 + C_6 - 0,620215 + C_7 - 0,526420 + C_8 - 0,086190 + C_9 - 0,370069 + C_{10} - 0,321707 + 0,14103191 \right] \\
 \phi_2 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,205895 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,018829 + C_1 - 0,121867 + C_2 - 0,057792 + C_3 - 0,090601 + C_4 - 0,347727 + C_5 - 0,452922 + C_6 - 0,070136 + C_7 - 0,168909 + C_8 - 0,019294 + C_9 - 0,530253 + C_{10} - 0,358080 - 0,20201149 \right] \\
 \phi_3 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,227812 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,373365 + C_1 - 0,593061 + C_2 - 0,133454 + C_3 - 0,231937 + C_4 - 0,272714 + C_5 - 0,328938 + C_6 - 0,069279 + C_7 - 0,552325 + C_8 - 0,115549 + C_9 - 0,040685 + C_{10} - 0,043664 - 0,02532302 \right] \\
 \phi_4 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,639307 + \left(\frac{h_t - 22,187}{2,594545265} \right) 0,005691 + C_1 - 0,433399 + C_2 - 0,220759 + C_3 - 0,100491 + C_4 - 0,295299 + C_5 - 0,525941 + C_6 - 0,699531 + C_7 - 0,323756 + C_8 - 0,197898 + C_9 - 0,562661 + C_{10} - 0,336141 - 0,57841389 \right] \\
 \phi_5 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,143356 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,426303 + C_1 - 0,071222 + C_2 - 0,052407 + C_3 - 0,221570 + C_4 - 0,321801 + C_5 - 0,502622 + C_6 - 0,441828 + C_7 - 0,313572 + C_8 - 0,002981 + C_9 - 0,467212 + C_{10} - 0,363692 - 0,00056108 \right] \\
 \phi_6 &= \\
 1 + \exp^{-2} \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,669462 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,084754 + C_1 - 0,247836 + C_2 - 0,121221 + C_3 - 0,326876 + C_4 - 0,261280 + C_5 - 0,211098 + C_6 - 0,341871 + C_7 - 0,362456 + C_8 - 0,359095 + C_9 - 0,027531 + C_{10} - 0,035728 + 0,13476539 \right]
 \end{aligned}$$

$$\text{ms}_{\text{copa}} = 4,906259067 (\phi_1 - 0,8795176148 + \phi_2 - 0,5240651369 + \phi_3 - 0,6285258532 + \phi_4 - 0,4899607003 + \phi_5 - 0,6626272798 + \phi_6 - 0,7489198446 + 0,1024724878) + 10,12001472$$

Sendo, $\phi_{1,2,3,4,5,6}$ as saídas dos neurônios 1, 2, 3, 4, 5 e 6, respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, h_t a altura total, em m e $C_{1,2,3,4,5,6,7,8,9,10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE FOLHAS

$$\begin{aligned} \phi_1 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,636591 + C_1 \cdot 0,217976 + C_2 \cdot 0,354065 + C_3 \cdot 0,105069 + C_4 \cdot 0,498561 + C_5 \cdot 0,390916 + C_6 \cdot 0,704203 + C_7 \cdot 0,453701 + C_8 \cdot 0,269154 + C_9 \cdot 0,339854 + C_{10} \cdot 0,226713 + 0,1691804904 \right)}}^{-1}} \\ \phi_2 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,672114 + C_1 \cdot 0,184537 + C_2 \cdot 0,467626 + C_3 \cdot 0,145455 + C_4 \cdot 0,024050 + C_5 \cdot 0,319783 + C_6 \cdot 0,056523 + C_7 \cdot 0,564221 + C_8 \cdot 0,141551 + C_9 \cdot 0,120151 + C_{10} \cdot 0,390094 + 0,2039064962 \right)}}^{-1}} \\ \phi_3 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,379881 + C_1 \cdot 0,017503 + C_2 \cdot 0,042444 + C_3 \cdot 0,022247 + C_4 \cdot 0,506429 + C_5 \cdot 0,099130 + C_6 \cdot 0,234833 + C_7 \cdot 0,260246 + C_8 \cdot 0,078100 + C_9 \cdot 0,352853 + C_{10} \cdot 0,048813 - 0,0543043617 \right)}}^{-1}} \\ \phi_4 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) - 0,206498 + C_1 \cdot 0,472558 + C_2 \cdot 0,484912 + C_3 \cdot 0,497917 + C_4 \cdot 0,508885 + C_5 \cdot 0,490302 + C_6 \cdot 0,273612 + C_7 \cdot 0,487136 + C_8 \cdot 0,368698 + C_9 \cdot 0,648186 + C_{10} \cdot 0,224081 + 0,0800102468 \right)}}^{-1}} \\ \phi_5 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) 0,293458 + C_1 \cdot 0,488365 + C_2 \cdot 0,413322 + C_3 \cdot 0,416975 + C_4 \cdot 0,553026 + C_5 \cdot 0,108506 + C_6 \cdot 0,022982 + C_7 \cdot 0,166211 + C_8 \cdot 0,211941 + C_9 \cdot 0,406945 + C_{10} \cdot 0,605627 - 0,0470697911 \right)}}^{-1}} \\ \phi_6 &= \frac{2}{1 + \exp^{-2 \left(\left(\frac{\text{dap}_{cc} - 14,5435787}{2,594545265} \right) 0,334052 + C_1 \cdot 0,542340 + C_2 \cdot 0,537626 + C_3 \cdot 0,155067 + C_4 \cdot 0,098256 + C_5 \cdot 0,395645 + C_6 \cdot 0,100060 + C_7 \cdot 0,170065 + C_8 \cdot 0,309670 + C_9 \cdot 0,209137 + C_{10} \cdot 0,227129 - 0,0258733953 \right)}}^{-1}} \\ \text{co}_{\text{folhas}} &= 0,905970583 (\phi_1 - 0,8827245235 + \phi_2 - 0,713230372 + \phi_3 - 0,539500713 + \phi_4 - 0,466872156 + \phi_5 - 0,711244822 + \phi_6 - 0,527329207 + 0,0272140498) + 1,554785854 \end{aligned}$$

Sendo, $\phi_{1,2,3,4,5,6}$ as saídas dos neurônios 1, 2, 3, 4, 5 e 6, respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, e $C_{1,2,3,4,5,6,7,8,9,10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE GALHOS VIVOS

$$\begin{aligned} \phi_1 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,586667 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,029695 + C_1 - 0,213393 + C_2 - 0,392269 + C_3 - 0,170702 + C_4 - 0,401412 + C_5 - 0,349884 + C_6 - 0,555169 + C_7 - 0,465538 + C_8 - 0,057467 + C_9 - 0,351960 + C_{10} - 0,232165 + 0,24901636 \right]}} \\ \phi_2 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,115155 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,039094 + C_1 - 0,112541 + C_2 - 0,092687 + C_3 - 0,034917 + C_4 - 0,240119 + C_5 - 0,096728 + C_6 - 0,405023 + C_7 - 0,107672 + C_8 - 0,094617 + C_9 - 0,541049 + C_{10} - 0,502542 - 0,19640052 \right]}} \\ \phi_3 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,323322 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,255551 + C_1 - 0,604881 + C_2 - 0,033141 + C_3 - 0,182149 + C_4 - 0,359971 + C_5 - 0,296561 + C_6 - 0,077370 + C_7 - 0,516386 + C_8 - 0,184429 + C_9 - 0,033793 + C_{10} - 0,180894 - 0,08347078 \right]}} \\ \phi_4 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,603849 + \left(\frac{h_t - 22,187}{2,594545265} \right) 0,236884 + C_1 - 0,421165 + C_2 - 0,310040 + C_3 - 0,121642 + C_4 - 0,473060 + C_5 - 0,477693 + C_6 - 0,655621 + C_7 - 0,289343 + C_8 - 0,138009 + C_9 - 0,557913 + C_{10} - 0,456332 - 0,50776014 \right]}} \\ \phi_5 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) 0,120616 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,424227 + C_1 - 0,047228 + C_2 - 0,055087 + C_3 - 0,145914 + C_4 - 0,222154 + C_5 - 0,535440 + C_6 - 0,473534 + C_7 - 0,260350 + C_8 - 0,047315 + C_9 - 0,455812 + C_{10} - 0,473906 - 0,10814428 \right]}} \\ \phi_6 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{\text{dap}_{cc} - 14,543}{2,594545265} \right) - 0,650352 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,071816 + C_1 - 0,284228 + C_2 - 0,004935 + C_3 - 0,392351 + C_4 - 0,358859 + C_5 - 0,221075 + C_6 - 0,310600 + C_7 - 0,433169 + C_8 - 0,350385 + C_9 - 0,002003 + C_{10} - 0,073026 + 0,13067680 \right]}} \\ \text{CO}_{\text{galhos vivos}} &= 0,978167256 (\phi_1 - 0,6787919402 + \phi_2 - 0,4328284264 + \phi_3 - 0,6863356233 + \phi_4 - 0,6553181410 + \phi_5 - 0,4775994122 + \phi_6 - 0,7707935572 + 0,0885842201) + 1,776913716 \end{aligned}$$

Sendo, $\phi_1, \phi_2, \phi_3, \phi_4, \phi_5$ e ϕ_6 , respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, h_t a altura total, em m e $C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9, C_{10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

CONJUNTO DE EQUAÇÕES DESENVOLVIDAS POR REDE NEURAL ARTIFICIAL PARA ESTIMAR O CARBONO ORGÂNICO ESTOCADO NO COMPONENTE COPA

$$\begin{aligned} \phi_1 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) - 0,645223 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,231991 + C_1 - 0,207267 + C_2 - 0,279943 + C_3 - 0,269458 + C_4 - 0,501353 + C_5 - 0,369848 + C_6 - 0,623361 + C_7 - 0,520017 + C_8 - 0,074334 + C_9 - 0,370787 + C_{10} - 0,317058 + 0,13457363 \right]}} \\ \phi_2 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) - 0,202983 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,014524 + C_1 - 0,124499 + C_2 - 0,050279 + C_3 - 0,081569 + C_4 - 0,357781 + C_5 - 0,066457 + C_6 - 0,445376 + C_7 - 0,161933 + C_8 - 0,032194 + C_9 - 0,528999 + C_{10} - 0,360272 - 0,19406467 \right]}} \\ \phi_3 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) 0,218632 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,364288 + C_1 - 0,593655 + C_2 - 0,131869 + C_3 - 0,235734 + C_4 - 0,265731 + C_5 - 0,331932 + C_6 - 0,074887 + C_7 - 0,549220 + C_8 - 0,126745 + C_9 - 0,042113 + C_{10} - 0,045129 - 0,02350354 \right]}} \\ \phi_4 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) 0,635148 + \left(\frac{h_t - 22,187}{2,594545265} \right) 0,006015 + C_1 - 0,431092 + C_2 - 0,224783 + C_3 - 0,099900 + C_4 - 0,296731 + C_5 - 0,530497 + C_6 - 0,698189 + C_7 - 0,316059 + C_8 - 0,187624 + C_9 - 0,557322 + C_{10} - 0,339557 - 0,56555042 \right]}} \\ \phi_5 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) 0,146935 + \left(\frac{h_t - 22,187}{2,52154713} \right) - 0,424887 + C_1 - 0,072151 + C_2 - 0,049848 + C_3 - 0,223057 + C_4 - 0,326323 + C_5 - 0,499284 + C_6 - 0,441115 + C_7 - 0,308181 + C_8 - 0,009031 + C_9 - 0,468996 + C_{10} - 0,367504 + 0,00048807 \right]}} \\ \phi_6 &= \frac{2}{1 + \exp^{-2 \left[\left(\frac{dap_{cc} - 14,543}{2,594545265} \right) - 0,672014 + \left(\frac{h_t - 22,187}{2,52154713} \right) 0,077651 + C_1 - 0,244690 + C_2 - 0,114535 + C_3 - 0,327699 + C_4 - 0,262667 + C_5 - 0,209103 + C_6 - 0,340958 + C_7 - 0,368985 + C_8 - 0,353222 + C_9 - 0,029673 + C_{10} - 0,032487 + 0,12142353 \right]}} \end{aligned}$$

$$co_{copa} = 2,236031905 (\phi_1 - 0,8876283765 + \phi_2 - 0,5109692812 + \phi_3 - 0,6363118887 + \phi_4 - 0,4857781231 + \phi_5 - 0,6660707593 + \phi_6 - 0,7360643744 + 0,0968739946) + 4,623777908$$

Sendo, $\phi_{1,2,3,4,5,6}$ as saídas dos neurônios 1, 2, 3, 4, 5 e 6, respectivamente, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, h_t a altura total, em m e $C_{1,2,3,4,5,6,7,8,9,10}$ os materiais genéticos C-406, C-408, C-432, C-435, C-436, C-443, C-455, C-479, C-490, C-500, respectivamente.

EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR PARA ESTIMAR A BIOMASSA SECA DOS COMPONENTES GALHOS SECOS, CASCA, LENHO, TOTAL E TRONCO

$$ms_{\text{galhos secos}} = 1,6434801 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,0127908 (h_t^2) + 0,0007269 (dap_{cc} h_t^2)$$

$$ms_{\text{casca}} = -1,4052076 (1 - \exp^{(0,1200046 \text{ dap}_{cc})})$$

$$ms_{\text{lenho}} = 3,0032792 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,1503733 (h_t^2) + 0,0179483 (dap_{cc} h_t^2)$$

$$ms_{\text{total}} = 0,0170491 (dap_{cc}^2 h_t)^{1,0127745}$$

$$ms_{\text{tronco}} = 3,2155643 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,1659968 (h_t^2) + 0,0194305 (dap_{cc} h_t^2)$$

EQUAÇÕES DESENVOLVIDAS POR REGRESSÃO NÃO LINEAR PARA ESTIMAR O CARBONO ORGÂNICO ESTOCADO NOS COMPONENTES GALHOS SECOS, CASCA, LENHO, TOTAL E TRONCO

$$co_{\text{galhos secos}} = 1,6434801 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,0127908 (h_t^2) + 0,0007269 (dap_{cc} h_t^2)$$

$$co_{\text{casca}} = -1,4052076 (1 - \exp^{(0,1200046 \text{ dap}_{cc})})$$

$$co_{\text{lenho}} = 3,0032792 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,1503733 (h_t^2) + 0,0179483 (dap_{cc} h_t^2)$$

$$co_{\text{total}} = 0,0170491 (dap_{cc}^2 h_t)^{1,0127745}$$

$$co_{\text{tronco}} = 3,2155643 \left(2 + \frac{dap_{cc}}{h_t} \right) - 0,1659968 (h_t^2) + 0,0194305 (dap_{cc} h_t^2)$$

Sendo, dap_{cc} o diâmetro com casca medido a 1,30 m de altura, em cm, e h_t a altura total, em m.